

**Masarykova univerzita  
Filozofická fakulta**

**Ústav pedagogických věd  
Pedagogika**

Mgr. Bc. Libor Juhaňák

**Analytika učení a data mining ve vzdělávání  
v kontextu systémů pro řízení výuky**

*Disertační práce*

Vedoucí práce: doc. Mgr. Jiří Zounek, Ph.D.

**2020**



*Prohlašuji, že jsem disertační práci vypracoval samostatně  
s využitím uvedených pramenů a literatury.*

.....

Podpis autora práce



*Na tomto místě bych velice rád poděkoval svému školiteli doc. Jiřímu Zounekovi,  
a to nejen za celkovou podporu v průběhu psaní této disertační práce,  
ale především za důvěru, že její psaní jednoho dne skončí.*

*Rovněž bych rád poděkoval všem kolegyním a kolegům  
z Ústavu pedagogických věd, se kterými jsem měl  
tu čest během svého doktorského studia  
spolupracovat a učit se od nich.*

*V neposlední řadě bych rád  
poděkoval přátelům,  
a zvláště rodině,  
za všechno.*

*Děkuji.*



## Stručný obsah práce

Úvod.....	13
1. Teoreticko-metodologický kontext disertační práce .....	17
2. Analytika učení a data mining ve vzdělávání.....	51
3. Metodologie výzkumu.....	131
4. Sonda A – Analýza možností vybraných klasifikačních algoritmů pro účely predikce úspěšnosti studentů v blended kurzech.....	145
5. Sonda B – Analýza interakce studentů a učitelů v online diskuzních fórech s využitím analýzy sociálních sítí .....	183
6. Sonda C – Analýza chování studentů v průběhu plnění online testů s využitím metody dolování procesů.....	227
7. Diskuze výsledků disertační práce .....	253
Závěr .....	259
Seznamy zkratk, obrázku a tabulek .....	261
Použitá literatura .....	269





## Podrobný obsah práce

Úvod-----	13 -
1. Teoreticko-metodologický kontext disertační práce-----	17 -
1.1. Vytyčení výzkumného pole disertační práce -----	17 -
1.2. E-learning a systémy pro řízení výuky-----	24 -
1.2.1. E-learning -----	26 -
1.2.1.1. Online learning a blended learning-----	29 -
1.2.2. Systémy pro řízení výuky-----	31 -
1.2.2.1. LMS Moodle -----	35 -
1.3. Data science a exploratorní metody analýzy dat -----	36 -
1.3.1. Exploratorní analýza dat jako součást kvantitativního výzkumu -----	38 -
1.3.2. Vznik, vymezení a kritika data science -----	42 -
1.3.3. Vybrané pojmy související s oblastí data science-----	47 -
1.4. Shrnutí kontextu disertační práce -----	49 -
2. Analytika učení a data mining ve vzdělávání-----	51 -
2.1. Vznik a historické kořeny -----	51 -
2.1.1. Historické kořeny data miningu ve vzdělávání -----	55 -
2.1.2. Historické kořeny analytiky učení -----	57 -
2.1.3. Další oblasti formující analytiku učení a data mining ve vzdělávání-----	59 -
2.2. Základní vymezení a hlavní koncepty -----	62 -
2.2.1. Vymezení a konceptualizace data miningu ve vzdělávání-----	63 -
2.2.1.1. Proces data miningu ve vzdělávání-----	64 -
2.2.1.2. Typy dat využívané v rámci data miningu ve vzdělávání -----	69 -
2.2.1.3. Základní metody data miningu ve vzdělávání -----	74 -
2.2.2. Vymezení a konceptualizace analytiky učení -----	84 -
2.2.2.1. Úrovně analytiky ve vzdělávání -----	84 -
2.2.2.2. Proces analytiky učení -----	86 -
2.2.2.3. Dimenze analytiky učení-----	88 -

2.2.3. Srovnání data miningu ve vzdělávání a analytiky učení -----	90 -
2.2.3.1. Rozdílný vznik a vývoj v čase -----	91 -
2.2.3.2. Rozdílné využívání analytických metod a technik -----	94 -
2.2.3.3. Rozdílné zaměření pozornosti -----	95 -
2.3. Dosavadní směry výzkumů a řešená témata-----	96 -
2.3.1. Analytické nástroje pro sumarizaci a vizualizaci dat-----	99 -
2.3.2. Predikce úspěšnosti a identifikace rizikových studentů-----	100 -
2.3.3. Modelování studentů-----	102 -
2.3.3.1. Modelování znalostí a dovedností studentů -----	103 -
2.3.3.2. Modelování chování studentů-----	106 -
2.3.3.3. Modelování emocí a afektivních stavů -----	108 -
2.3.4. Adaptivní a doporučovací systémy -----	110 -
2.3.5. Sociální analytika učení-----	113 -
2.3.5.1. Analytika sociálních sítí -----	114 -
2.3.5.2. Analytika obsahu -----	116 -
2.3.5.3. Analytika diskurzu-----	117 -
2.3.6. Multimodální analytika učení-----	118 -
2.3.7. Etické aspekty analytiky učení a data miningu ve vzdělávání -----	122 -
2.4. Shrnutí a východiska pro empirickou část-----	127 -
3. Metodologie výzkumu-----	131 -
3.1. Výzkumné téma, cíle a design výzkumu-----	131 -
3.2. Zaměření dílčích výzkumných sond -----	136 -
3.3. Výzkumné otázky -----	138 -
3.4. Metody a techniky získávání a analýzy dat -----	139 -
3.5. Etické aspekty výzkumu -----	140 -
3.6. Limity zvoleného výzkumného postupu -----	142 -
4. Sonda A – Analýza možností vybraných klasifikačních algoritmů pro účely predikce úspěšnosti studentů v blended kurzech-----	145 -
4.1. Přehled dosavadních výzkumů k sondě A-----	147 -

4.1.1. Predikce úspěšnosti studentů v kontextu blended learningu a LMS -----	147 -
4.1.2. Temporální charakteristiky návštěvnosti jako prediktory úspěšnosti -----	151 -
4.1.3. Otázky zobecnitelnosti a přenositelnosti prediktivních modelů-----	153 -
4.2. Výzkumný problém a otázky sondy A -----	154 -
4.3. Metodologie sondy A -----	156 -
4.3.1. Metodologický přístup – klasifikace -----	157 -
4.3.2. Analyzovaná data, sběr a předzpracování dat -----	158 -
4.3.3. Použité proměnné -----	160 -
4.3.4. Postup analýzy dat-----	163 -
4.4. Výsledky sondy A -----	166 -
4.4.1. Základní posouzení predikčních schopností analyzovaných klasifikátorů ---	166 -
4.4.2. Hodnocení přínosnosti použitých prediktorů -----	173 -
4.4.3. Predikční testování externí validací -----	175 -
4.5. Diskuze a závěr sondy A -----	177 -
4.5.1. Shrnutí odpovědí na stanovené výzkumné otázky -----	178 -
4.5.2. Důsledky pro praxi a další výzkum -----	180 -
5. Sonda B – Analýza interakce studentů a učitelů v online diskuzních fórech s využitím analýzy sociálních sítí -----	183 -
5.1. Přehled dosavadních výzkumů k sondě B -----	184 -
5.1.1. Participace studentů v online diskuzích a její výzkum -----	186 -
5.1.2. Analýza sociálních sítí v kontextu e-learningu a LMS -----	189 -
5.1.3. Analýza sociálních sítí a interakce v online diskuzních fórech v LMS -----	191 -
5.2. Výzkumný problém a otázky sondy B -----	193 -
5.3. Metodologie sondy B -----	195 -
5.3.1. Metodologický přístup – analýza sociálních sítí-----	195 -
5.3.2. Postup sběru a předzpracování dat -----	197 -
5.3.3. Analýza dat -----	199 -
5.4. Výsledky sondy B -----	201 -
5.5. Diskuze a závěr sondy B-----	222 -

5.5.1. Shrnutí odpovědí na stanovené výzkumné otázky -----	222 -
5.5.2. Limity sondy a možnosti dalšího výzkumu -----	225 -
6. Sonda C – Analýza chování studentů v průběhu plnění online testů s využitím metody dolování procesů -----	227 -
6.1. Přehled dosavadních výzkumů k sondě C -----	228 -
6.1.1. Přístupy založené na person-fit indexech -----	230 -
6.1.2. Přístupy založené na rychlosti odpovídání -----	232 -
6.1.3. Přístupy vycházející z data miningu ve vzdělávání a analytiky učení -----	233 -
6.2. Výzkumný problém a otázky sondy C -----	235 -
6.3. Metodologie sondy C -----	236 -
6.3.1. Metodologický přístup – dolování procesů -----	236 -
6.3.2. Analyzované případy -----	238 -
6.3.3. Sběr a předzpracování dat -----	239 -
6.3.4. Analýza dat -----	241 -
6.4. Výsledky sondy C -----	242 -
6.5. Diskuze a závěr sondy C -----	248 -
6.5.1. Shrnutí odpovědí na stanovené výzkumné otázky -----	248 -
6.5.2. Limity sondy, možnosti dalšího výzkumu a důsledky pro praxi -----	250 -
7. Diskuze výsledků disertační práce -----	253 -
Závěr -----	259 -
Seznam zkratk -----	261 -
Seznam obrázků -----	263 -
Seznam tabulek -----	267 -
Použitá literatura -----	269 -

# Úvod

*It is a capital mistake to theorize before one has data.  
Insensibly one begins to twist facts to suit theories,  
instead of theories to suit facts.*

Sherlock Holmes

Arthur Conan Doyle (1891)

A Scandal in Bohemia

Problematiku informačních a komunikačních technologií (ICT) můžeme v kontextu současného pedagogického výzkumu považovat za jedno z dominantních témat. Přestože by bylo možné argumentovat, že český pedagogický výzkum této problematice nevěnuje až tolik pozornosti (srov. Zounek & Tůma, 2014), množství existujících zahraničních odborně zaměřených pedagogických časopisů specializujících se přímo na téma digitálních technologií ve vzdělávání nás nenechá na pochybách, že jde o problematiku, jíž se zabývá značné množství výzkumníků a odborníků (a to nejen přímo v kontextu vzdělávání a pedagogického výzkumu). Pozornost věnovaná moderním technologiím přitom není nijak zvlášť překvapivá, uvědomíme-li si, že se informační a komunikační technologie postupem času staly přirozenou součástí společnosti a každodenního života většiny lidí. Digitální technologie jsou v současnosti běžně využívány v řadě odvětví lidské činnosti, a to včetně vzdělávání a školství.

Jedním z důvodů, proč si problematika informačních a komunikačních technologií získala v pedagogickém výzkumu tak velkou pozornost je jistě i to, že jde o téma velmi různorodé a široké, a tudíž v řadě dílčích oblastí stále relativně nové a neprozkoumané. Výzkumníci se tak mohou této problematice věnovat ve velkém množství kontextů. Ať už v rámci různých pedagogických disciplín (obecná pedagogika, speciální pedagogika, andragogika, pedagogická evaluace a další), v souvislosti s různými aktéry vzdělávání (student, učitel) či třeba s ohledem na různé typy technologií, které mohou být ve vzdělávání využívány (od

počítačů, přes tablety a chytré telefony, až třeba po online výukové hry nebo tzv. rozšířenou či virtuální realitu). Navíc s neutuchajícím vývojem v oblasti digitálních technologií, který souvisí mimo jiné s exponenciálním růstem výpočetního výkonu počítačů (Moore, 1965), se objevují stále nové technologie a možnosti jejich využití ve vzdělávání.

Přesto i v rámci výzkumu digitálních technologií ve vzdělávání existují oblasti, kterým je pozornost věnována poměrně soustavně a dnes lze říci, že již i relativně dlouhodobě. Jednou z takových oblastí jsou systémy pro řízení výuky (*learning management systems*) běžně označované zkratkou LMS. Je to dáno tím, že systémy typu LMS se v kontextu vzdělávání staly prakticky „technologickým standardem“. Přestože je situace v oblasti využívání ICT ve školách a vzdělávání obecně přirozeně poměrně odlišná (a to jak napříč zeměmi, tak i napříč jednotlivými vzdělávacími institucemi), systémy typu LMS lze zvláště v případě institucí terciárního vzdělávání považovat v současnosti za široce až univerzálně rozšířené (srov. Ferguson, 2012a; Macfadyen & Dawson, 2012; Poulová, 2010).

Implicitní součástí většiny systémů typu LMS je přitom to, že automaticky sbírají a uchovávají data o svých uživateliích či o tom, jakými způsoby uživatelé daný systém využívají. Tato data mohou být zároveň poměrně bohatá. V případě studentů jakožto jedněch z hlavních uživatelů těchto systémů, může jít například o informace o kurzech, které studují, či které již absolvovali. Může jít také o studijní výsledky v jednotlivých kurzech, a to i v rámci dílčích výukových aktivit daného kurzu. Stejně tak mohou systémy typu LMS uchovávat informaci o komunikaci studentů s vyučujícím a s ostatními studenty kurzu či např. obecnou informaci o tom, jak často a jak aktivně se vlastně studenti aktivně zapojují do odpovídajícího kurzu v LMS. Až do relativně nedávné doby však zůstávaly tyto online výukové systémy v určitém ohledu černými skříňkami. Přestože řadu let automaticky shromažďovaly a ukládaly výše nastíněné typy informací a dat, jen ojediněle byla tato data systematicky využívána pro účely výzkumu či v souvislosti se zkvalitňováním vzdělávání prostřednictvím těchto výukových systémů v rámci dané vzdělávací instituce.

Výraznější změna nastala teprve v posledních letech spolu s rozvojem specifických výzkumných oblastí, jež začaly být označovány jako data mining ve vzdělávání (*educational data mining*) a analytika učení (*learning analytics*). Oblasti data miningu ve vzdělávání začala být věnována zvýšená pozornost na přelomu let 2008 a 2009 (Romero & Ventura, 2013), oblast analytiky učení pak zaznamenala výraznější rozvoj zvláště po roce 2012, přestože za její „zrod“ lze považovat přelom let 2010 a 2011 (Ferguson, 2012; Juhaňák & Zounek, 2016; Siemens, 2013). Přestože jsou mezi data miningem ve vzdělávání a analytikou učení dílčí rozdíly, hlavním cílem obou těchto výzkumných oblastí je snaha co nejvíce využít potenciál unikátních dat, která jsou generována a ukládána různými online

vzdělávacími prostředími jako jsou právě systémy typu LMS. Pro tyto účely jsou přitom vyvíjeny a následně používány různé analytické a data miningové metody a postupy, které by měly umožnit získat důležité informace a poznatky o tom, jak se studenti v online výukových prostředích chovají a učí.

Vzhledem k mému odbornému zájmu o systémy typu LMS a mému někdejšímu působení na pozici e-learningového specialisty a administrátora LMS Moodle na Filozofické fakultě Masarykovy univerzity mě přirozeně tyto nově se formující oblasti velmi zaujaly. Tento zájem se následně přetavil do formy doktorského studia a disertační projektu, v rámci kterého vznikla předkládaná disertační práce. V kontextu českého pedagogického výzkumu přitom analytice učení ani data miningu ve vzdělávání v té době nebyla věnována žádná nebo jen velmi nepatrná pozornost, přestože v zahraničí šlo postupně o stále více akcentované výzkumné téma a sílící trend. To vše mě vedlo k cíli využít metody analytiky učení a data miningu ve vzdělávání pro analýzu dat z LMS Moodle provozovaného na Filozofické fakultě Masarykovy univerzity a svým disertačním projektem zabývajícím se těmito „novými“ metodami tak přispět k obohacení dosavadního pedagogického výzkumu.

S ohledem na výše naznačený cíl pak byla koncipována i předkládaná disertační práce. Disertační práci tak tvoří celkem sedm základních kapitol. První kapitola nabízí především uvedení do kontextu řešeného tématu. A to jednak skrze základní vytyčení výzkumného pole disertační práce v podobě prvotního přiblížení oblastí analytiky učení a data miningu ve vzdělávání, jednak také skrze podrobné rozpracování teoretického a metodologického kontextu obou oblastí. V této kapitole tak nejprve podávám výchozí definici data miningu ve vzdělávání a analytiky učení, jakožto oblastí stojících na pomezí e-learningu a data science. Následně podrobněji nastiňuji teoretický kontext disertační práce, kde vedle samotného pojmu e-learning přibližuji i další související pojmy stěžejní pro tuto práci. Zároveň věnuji pozornost vymezení a představení systémů typu LMS, na které se zaměřuje empirická část práce. Poté se věnuji metodologickému kontextu disertační práce, za který lze s ohledem na vymezení analytiky učení a data miningu ve vzdělávání považovat oblast data science a problematiku exploratorních metod analýzy dat. Zde přitom nastiňuji jak historický kontext data science jakožto specifické odnože klasické statistiky, tak i kritické ohlasy, které se v souvislosti s tímto pojmem objevují.

Obsah druhé kapitoly lze pak považovat za podrobnou přehledovou studii obou oblastí zájmu, tj. jak data miningu ve vzdělávání, tak i analytiky učení. V kapitole mapuji vznik a „historický“ kontext obou řešených oblastí a poukazuji na další oblasti výzkumu, které při formování analytiky učení a data miningu ve vzdělávání sehrály důležitou roli. Dále podávám podrobnější definici obou oblastí a představuji důležité pojmy a koncepty, se kterými se

v těchto oblastech pracuje. Rovněž popisují různé typy dat a analytických metod či technik, které jsou v data miningu ve vzdělávání a analytice učení nejčastěji využívány. Na tomto základě nastiňuji základní rozdíly mezi jednotlivými oblastmi. Druhou kapitolu zakončuji podrobným přehledem témat či směrů výzkumu, jež jsou v oblasti analytiky učení a data miningu ve vzdělávání řešeny a kterým je věnována největší výzkumná pozornost.

Ve třetí kapitole je představen a popsán zvolený metodologický postup disertační práce. Vzhledem k zaměření pozornosti na relativně nové oblasti analytiky učení a data miningu ve vzdělávání nebylo možné zvolit některý ze zavedených a běžně využívaných výzkumných designů, nýbrž jsem musel přistoupit k návrhu vlastního výzkumného designu. Abych mohl co nejlépe naplnit věcné i metodologické cíle práce (tj. jednak mapování různých aspektů učení a výuky v systémech typu LMS, jednak zhodnocení možností a přínosu analytických metod a technik pocházejících z oblasti data miningu ve vzdělávání a analytiky učení), koncipoval jsem empirickou část práce jako sérii paralelních výzkumných sond zaměřujících se na vybrané aspekty učení a výuky v systémech typu LMS a využívajících různé metodologické přístupy z oblasti analytiky učení a data miningu ve vzdělávání.

Následující tři kapitoly (tj. kapitoly 4, 5 a 6) pak postupně představují jednotlivé realizované sondy. Zaměření první sondy směřuje k možnostem využití vybraných klasifikačních algoritmů pro účely predikce úspěšnosti studentů v blended kurzech. V rámci predikce jsou přitom využity různé temporální charakteristiky týkající se návštěvnosti e-learningových opor kurzů v LMS. Druhá sonda věnuje pozornost interakci studentů a učitelů v online diskuzních fórech, přičemž pro jejich zkoumání využívá analýzu sociálních sítí. Třetí realizovaná sonda pak sleduje možnosti využití metody dolování procesů pro účely analýzy a detekce různých forem chování studentů v průběhu plnění online testů.

Poslední sedmá kapitola nakonec shrnuje a diskutuje hlavní výsledná zjištění jednotlivých realizovaných sond a práce jako celku. Poté, co jsem v předchozích kapitolách zaměřoval pozornost na problematiku jednotlivých sond, se tak v této části vracím opět na obecnější úroveň a k obecnému cíli práce. Reflektuji přitom jak věcnou, tak i metodologickou stránku práce a ukazuji, jaké poznatky přineslo využití metod analytiky učení a data miningu ve vzdělávání pro analýzu učení a výuky v systémech pro řízení výuky.



# 1. Teoreticko-metodologický kontext disertační práce

Před samotným zaměřením se na analytiku učení a data mining ve vzdělávání a před poskytnutím podrobného přehledu týkajícího se těchto dvou oblastí, považuji za nezbytné poskytnout čtenáři nejprve širší kontext této problematiky. Primárním důvodem je to, že jak data mining ve vzdělávání, tak i analytika učení jsou relativně nové oblasti, jež jsou zvláště v kontextu české pedagogiky zatím řešeny jen velmi ojediněle. Čtenář tak s těmito oblastmi nemusí být dosud seznámen. Sekundárním důvodem je pak určitá specifická analytika učení a data miningu ve vzdělávání, neboť se jedná o oblasti, které se vymezují spíše používanými výzkumnými resp. analytickými metodami (tj. data mining resp. analytika), než určitým obsahovým či věcným zaměřením. Tomu pak odpovídá i pojetí této práce, jež se na obě tyto oblasti zaměřuje a musí tak nutně reflektovat i toto jejich metodologické zaměření. Úkolem úvodní kapitoly je proto jednak prvotní přiblížení obou řešených oblastí, než jim bude věnována podrobnější pozornost v následující přehledové kapitole, jednak také ukotvení obou oblastí do kontextu pedagogiky a pedagogického výzkumu.

V podkapitole 1.1 nejprve podávám výchozí vymezení oblasti analytiky učení a data miningu ve vzdělávání, podrobněji specifikuji zaměření práce a nastiňuji širší teoreticko-metodologický kontext. V podkapitole 1.2 poté přistupuji k teoretickému resp. věcnému ukotvení data miningu ve vzdělávání a analytiky učení v rámci široké výzkumné oblasti zaměřující se na moderní technologie ve vzdělávání. Současně podrobněji popisují tzv. systémy pro řízení výuky (*learning management systems – LMS*), jakožto specifický typ online vzdělávacích systémů, na které se v souvislosti s využitím metod analytiky učení a data miningu ve vzdělávání zaměřuje celá disertační práce. Ve třetí podkapitole pak poskytnu metodologické ukotvení analytiky učení a data miningu ve vzdělávání, přičemž ukáži, že tyto relativně nové výzkumné oblasti lze s ohledem na používané metody zařadit do širšího kontextu metod exploratorní analýzy dat, které se začaly bouřlivě rozvíjet přibližně od 60. let minulého století a vedly až ke vzniku oblastí jako data mining, strojové učení či data science, jež se v současnosti vedle pedagogiky začínají promítat i do řady dalších vědních disciplín.

## 1.1. Vytyčení výzkumného pole disertační práce

Oblast **data miningu ve vzdělávání** (*educational data mining – EDM*) lze spolu s Romerem a Venturou (2013) chápat jednoduše jako využití či aplikaci metod data miningu na různé specifické typy dat, která pochází ze vzdělávacího kontextu. Ať již jde o data pocházející přímo z LMS či o data z jiných typů online ale i off-line vzdělávacích systémů. Jak bylo zmíněno v úvodu kapitoly, vidíme zde jasnou tendenci vymezovat tuto výzkumnou oblast

na základě používaných metod pro analýzu dat (tj. data mining). Podobně i Baker a Yacefová (2009) zdůrazňují při vymezení data miningu ve vzdělávání metodologické aspekty. Přitom ale rozlišují na jedné straně to, že se data mining ve vzdělávání zabývá rozvojem metod pro analýzu dat z různých vzdělávacích prostředí, na druhé straně pak také to, že se zabývá i aplikací těchto metod za účelem porozumění učení studentů v různých typech (zvláště online) vzdělávacích prostředí. Vidíme zde tedy zaměření jednak na rozvoj specifické metodologie, jednak na samotné věcné zkoumání problematiky učení a vzdělávání.

**Analytiku učení** (*learning analytics – LA*) pak lze v prvotním přiblížení chápat do značné míry podobně jako data mining ve vzdělávání. Při vymezení této oblasti sice již autoři obvykle nestaví na relativně jasně vymezené skupině metod, přesto, podobně jako v případě data miningu ve vzdělávání, zmiňují určitou formu či způsob analýzy<sup>1</sup> specifických typů dat ze vzdělávacích prostředí (srov. Long & Siemens, 2011). Long a Siemens pak podobně jako Baker a Yacefová (2009) zdůrazňují rovněž věcný cíl, kterým je u analytiky učení (stejně jako u data miningu ve vzdělávání) porozumění učení studentů v různých vzdělávacích prostředích<sup>2</sup>. Oproti data miningu ve vzdělávání pak Long a Siemens (2011) při vymezení analytiky učení explicitně doplňují ještě i aplikační cíl analytiky učení, kterým je optimalizace vzdělávacích prostředí, ve kterých učení studentů probíhá, a tím zprostředkovaně i optimalizace učení jako takového. Nutno však doplnit, že ačkoli se tento aspekt explicitně nevyskytuje ve výše uváděných definicích data miningu ve vzdělávání (srov. také přehled definic v kapitole 2.2.1.), lze ho považovat za platný i v této oblasti. Stejně jako oblast analytiky učení zahrnuje totiž i oblast data miningu ve vzdělávání aplikační stránku problematiky<sup>3</sup> a s tím související snahu o optimalizaci.

Jak je z výše nastíněného základního vymezení data miningu ve vzdělávání a analytiky učení patrné, obě oblasti jsou si velmi podobné. A přestože dále v textu (konkrétně část 2.2.3.) bude věnována podrobnější pozornost jejich srovnání a identifikaci hlavních rozdílů mezi

---

<sup>1</sup> V asi nejpoužívanější definici analytiky učení od Longa a Siemense (2011) je zdůrazňováno široké pojetí analytického procesu. Autoři tak mimo vlastní fázi analýzy explicitně zmiňují i fázi měření, sběru dat a reportování výsledků analýzy.

<sup>2</sup> Přestože se Long a Siemens (2011) spolu s některými dalšími autory záměrně vyhýbají omezení pouze na online vzdělávací prostředí či obecně nějaké technologicky zprostředkované učební prostředí, jak upozorňuje například Fergusonová (2012a), obvykle jde právě o online výukové systémy (např. LMS, různé tutorské či adaptivní systémy apod.), které automaticky sbírají velké množství dat, jež je možné následně analyzovat.

<sup>3</sup> Určitá aplikační stránka je velmi často významnou součástí výzkumů v těchto oblastech a není neobvyklé, že výzkum probíhá ve spojení či v návaznosti na předchozí vývoj určité aplikace či konkrétního technického řešení.

oběma oblastmi, v tomto prvotním přiblížení lze obě oblasti považovat vesměs za identické, jelikož sdílejí následující definiční charakteristiky:

1. Zabývají se rozvojem a využitím specifických analytických metod.
2. Zaměřují se na analýzu dat (především) z různých typů online vzdělávacích systémů.
3. Zkoumají učení a vzdělávání (především) v různých online vzdělávacích prostředích.

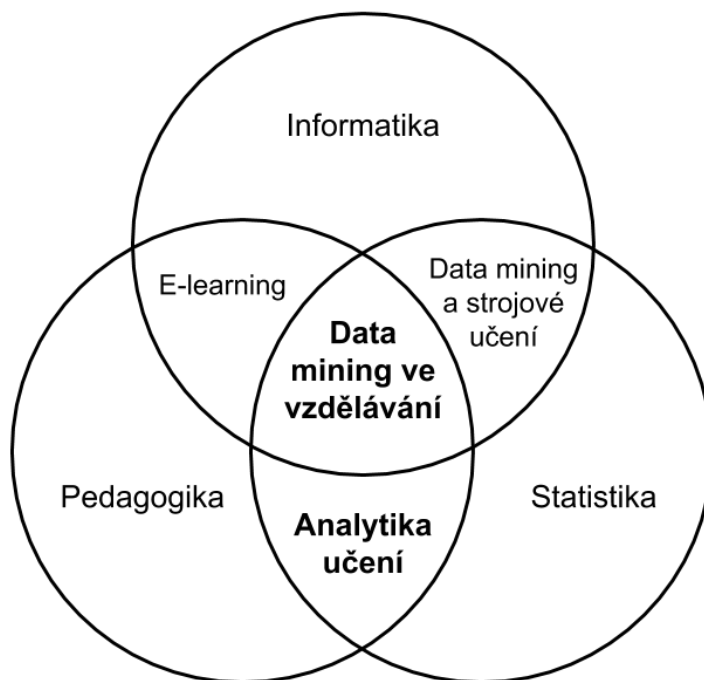
Jak data mining ve vzdělávání, tak i analytika učení přitom obvykle bývají chápány jako **interdisciplinární výzkumné oblasti**<sup>4</sup>, přičemž v odborných zdrojích zabývajících se touto problematikou je pro vymezení této interdisciplinarity používáno především znázornění Romera a Ventury (2013) v podobě Vennova diagramu (obrázek 1). Ti chápou data mining ve vzdělávání (resp. analytiku učení) jakožto oblast na pomezí tří základních disciplín: pedagogiky (*education*), informatiky (*computer science*) a statistiky (*statistics*).

Oblast data miningu ve vzdělávání je pak v pojetí těchto autorů chápána jako průnik všech tří disciplín, tj. průnik pedagogiky, informatiky a statistiky. Vedle průniku všech tří základních disciplín pojmenovávají uvedení autoři i průniky jednotlivých dvojic disciplín. Za průnik mezi pedagogikou a informatikou je považována oblast počítačem podporovaného resp. na počítačích založeného vzdělávání (*computer-based education*), kterou lze vesměs ztotožnit s tím, co bývá označováno pojmem *e-learning* či souslovím *vzdělávací technologie*<sup>5</sup>. Průnik mezi informatikou a statistikou je pak autory považován za oblast data miningu a strojového učení (*machine learning*) a průnik mezi statistikou a pedagogikou chápou autoři jako analytiku učení. Vedle průniku pedagogiky, informatiky a statistiky lze tak data mining ve vzdělávání v pojetí Romera a Ventury (2013) chápat také jako průnik analytiky učení, e-learningu (resp. počítačem podporovaného vzdělávání) a data miningu spolu se strojovým učením.

---

<sup>4</sup> Je otázkou, zda je označení této oblasti jakožto „interdisciplinární“ skutečně vhodné a odpovídající realitě, a zda by nebylo více odpovídající jiné označení (tj. multidisciplinární či transdisciplinární). V textu se však tohoto označení s ohledem na studované odborné zdroje přidrží.

<sup>5</sup> Jak upozorňuje např. Zounek (2009) při mapování historických kořenů e-learningu, panuje v této oblasti značná terminologická nejednotnost a v průběhu let se objevovala řada různých pojmenování, mezi kterými nejsou žádné či jen velmi malé rozdíly.



Obrázek 1: Základní vymezení oblasti data miningu ve vzdělávání a analytiky učení (dle Romero & Ventura, 2013).

Přestože jde o jednoduché, a tudíž nutně pouze hrubé vymezení jednotlivých oblastí, lze jej v určitých ohledech považovat za relativně funkční. Oblast e-learningu a vzdělávacích technologií lze skutečně v jistém smyslu chápat jako výzkumnou oblast na pomezí pedagogiky a informatiky. Podobně oblast data miningu a strojového učení čerpá na jedné straně ze statistiky a na druhé straně z informatiky (zvláště pak z oblastí vztahujících se k ukládání a zpracování dat, tj. databázové systémy, datové struktury, algoritmy apod.). Někteří autoři (např. Siemens, 2013) pak také chápou analytiku učení jako širší oblast oproti data miningu ve vzdělávání, tudíž by i v tomto ohledu byl Romerův a Venturův diagram odpovídající, jelikož v něm data mining ve vzdělávání zaujímá pouze tu část analytiky učení, u které současně dochází k průniku s (obecným) data miningem a strojovým učením. Postavení analytiky učení v diagramu je ovšem zároveň poměrně problematické a v tomto ohledu tak lze s diagramem souhlasit jen velmi obtížně. Analytika učení je totiž v diagramu ztotožněna s průnikem mezi pedagogikou a statistikou. Takové pojetí by však znamenalo až příliš velké rozšíření pojmu „analytika učení“. Za analytiku učení by totiž byly označeny i takové případy, které zcela jednoznačně s oblastí analytiky učení nijak nesouvisí.

Uvedu dva základní problémy takového vymezení analytiky učení. Prvním a méně významným problémem je to, že by do oblasti analytiky učení spadaly i takové případy, které se nijak netýkají e-learningu či oblasti informačních a komunikačních technologií ve

vzdělávání. To by sice odpovídalo široce přijímané definici Longa a Siemense (2011), která také neomezuje analytiku učení pouze na digitální technologie či online prostředí. Na druhou stranu, by to bylo do značné míry v rozporu s realitou, kde v současnosti stále převažuje zaměření výzkumníků v oblasti analytiku učení právě na e-learning a učení v online prostředí (srov. například přehledové studie Papamitsiou & Economides, 2014 a Peña-Ayala, 2018 či knihu Peña-Ayala, 2017). I přesto by však uvedený problém nemusel být považován za podstatný, jelikož by se dalo namítnout, že současné zaměření se na e-learning a online učební prostředí pramení jednoduše ze snadnější dostupnosti dat v těchto oblastech. A je tudíž možné, že postupem času se zájem analytiku učení přesune i do „off-line sféry“<sup>6</sup>.

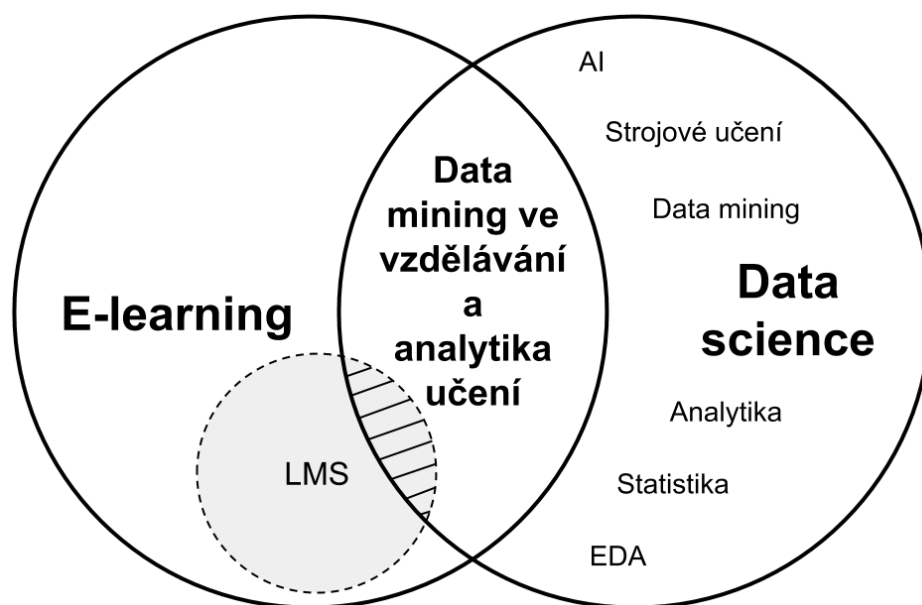
Druhý z problémů vymezení analytiku učení dle Romera a Ventury (2013) je však zcela fundamentální a, jak se domnívám, činí takové pojetí analytiku učení neudržitelným. Budeme-li totiž analytiku učení pojímat jako oblast tvořenou průnikem mezi pedagogikou a statistikou, pak by vesměs veškerý kvantitativně orientovaný pedagogický výzkum byl analytikou učení. Tzn., že jakékoli využití statistických metod v pedagogickém výzkumu by spadalo do oblasti označené jako analytika učení. Takové pojetí analytiku učení přitom samozřejmě není přijatelné, jelikož fakticky existuje řada kvantitativně orientovaných výzkumů v oblasti pedagogiky, které s analytikou učení nemají nic společného. Typickým příkladem může být velká skupina výzkumů zahrnujících statistickou analýzu dat z různých typů dotazníkových šetření. Je tedy zřejmé, že průnik mezi pedagogikou a statistikou je příliš velký na to, aby mohl být celý označen za analytiku učení. Jistě, v rámci analytiku učení se rovněž využívají statistické metody, ale v celém kontextu využití statistických metod v pedagogickém výzkumu tvoří analytika učení pouze relativně malou (a navíc do značné míry specifickou) podoblast.

Z důvodu výše nastíněné problematičnosti způsobu, jakým Romero a Ventura (2013) vymezují oblast data miningu ve vzdělávání, a především oblast analytiku učení, navrhuji níže vlastní zjednodušené, ale zároveň, jak věřím, přesnější vymezení (viz obrázek 2). Dle tohoto pojetí zaujímají data mining ve vzdělávání i analytika učení stejný prostor čili jsou chápány jako vesměs identické oblasti. Zde jde o zjednodušení, které bude v druhé kapitole do jisté míry zpřehledněno. Pro účely prvotního přiblížení lze ovšem nyní obě oblasti považovat za vesměs identické, jelikož sdílejí hlavní definiční charakteristiky. Data mining ve vzdělávání a analytika učení jsou přitom v tomto výchozím vymezení chápány jako průnik mezi oblastí

---

<sup>6</sup> Jak ukáží v druhé kapitole, někteří výzkumníci skutečně již začínají experimentovat s využitím metod analytiku učení i mimo virtuální či online prostředí.

e-learningu a oblastí označovanou jako data science<sup>7</sup>. Proto také každé z těchto dvou oblastí věnuji dále jednu z následujících kapitol. Zde proto pouze stručně: e-learningem rozumím oblast pedagogiky, která se zaměřuje na problematiku využívání digitálních technologií ve vzdělávání (srov. Zounek, 2009; Zounek & Sudický, 2012; Zounek et al., 2016). Oblastí označovanou jako data science se pak rozumí relativně nově se formující multidisciplinární oblast, která se zaměřuje na analýzu dat v širších souvislostech a v rámci které dochází k využití a kombinaci poznatků z oblastí a disciplín jako jsou statistika, matematika, informatika, data mining či strojové učení.



Obrázek 2: Návrh výchozího vymezení data miningu ve vzdělávání a analytiky učení včetně základního vytyčení oblasti, na kterou se zaměřuje tato disertační práce (šrafovaná oblast).

Diagram výše zároveň ilustruje zaměření této disertační práce. V kontextu analytiky učení a data miningu ve vzdělávání se totiž práce zaměřuje primárně na specifický typ online vzdělávacích systémů označovaný jako **systemy pro řízení výuky** (*learning management systems – LMS*)<sup>8</sup>. Problematika učení a výuky v LMS je jednou z poměrně výrazných

<sup>7</sup> Přestože se lze setkat i s použitím českých označení jako „datová věda“ či „věda o datech“, zřejmě nejčastěji je stále používáno původní anglické označení, kterého se proto přidržuji i v této práci.

<sup>8</sup> Někteří autoři používají rovněž překlad „systemy pro řízení učení“ (viz např. Zounek & Sudický, 2012) či „řídící výukový systém“ (Klement & Dostál, 2018). V práci se přidržuji označení „systemy pro řízení výuky“, které je v českém prostředí asi nejrozšířenější.

výzkumných oblastí, kterým je v kontextu e-learningu věnována pozornost. Důvodem je jednak to, že v případě systémů typu LMS nejde o zcela novou technologii, nýbrž tyto systémy za sebou mají již relativně dlouhou historii (alespoň na poměry rychlosti vývoje nových technologií ve vzdělávání), jednak také značná rozšířenost systémů toho typu, zvláště pak na univerzitách a vysokých školách. Např. Fergusonová (2012a) zmiňuje, že ve Velké Británii již v roce 2003 využívalo přes 85 % institucí terciárního vzdělávání nějaký systém typu LMS. Na podobná čísla v USA pak odkazují Macfadyen a Dawson (2012), kteří uvádí, že k roku 2010 více jak 90 % institucí terciárního vzdělávání výrazně investovalo do celouniverzitní implementace nějakého webového LMS. V České republice pak dle Poulové (2010) téměř všechny vysoké školy využívají nějaký LMS. Výjimku tvoří pouze školy umělecky zaměřené.

Problematika učení a výuky v systémech typu LMS je pak v oblasti e-learningu zkoumána pomocí různých výzkumných metod a přístupů, přičemž doposud stále převažují spíše „tradiční“ výzkumné postupy, ať již kvantitativně či kvalitativně orientované. Příkladem takového výzkumu v českém kontextu je např. studie Švaříčka a Zounka (2008), kteří se stejně jako tato disertační práce zaměřovali na využívání LMS Moodle na Filozofické fakultě Masarykovy univerzity. Autoři však využili smíšený výzkumný design kombinující hloubkové rozhovory s učiteli na jedné straně a kvantitativní obsahovou analýzu e-kurzů na straně druhé. S rozvojem analytiky učení a data miningu ve vzdělávání se však začaly ve výzkumu LMS stále více využívat i nové či netradiční metody vycházející z analýzy automaticky sbíraných dat o chování uživatelů těchto systémů (tj. studentů a učitelů).

Zaměření této disertační práce lze chápat jako průnik oblasti data miningu ve vzdělávání a analytiky učení s problematikou učení a výuky v systémech typu LMS (na diagramu výše jde o šrafovanou oblast). Konkrétně se práce věnuje možnostem využití metod analytiky učení a data miningu ve vzdělávání pro analýzu učení a výuky v LMS Moodle na Filozofické fakultě Masarykovy univerzity, přičemž sleduje jak metodologické otázky (tj. jaké metody EDM a LA lze v souvislosti s výzkumem LMS využít), tak i otázky obsahové či věcné (tj. co lze pomocí těchto metod zjistit).<sup>9</sup>

---

<sup>9</sup> Zároveň je vhodné upozornit, že ačkoli se práce věnuje primárně systémům typu LMS, které budou podrobněji představeny v kapitole 1.2.2., v rámci přehledové části (tj. kapitola 2) je věnována pozornost oblastem data miningu ve vzdělávání a analytiky učení jakožto celku a je tak podán širší přehled těchto oblastí nezaměřující se pouze na systémy typu LMS. V dalších částech práce (tj. kapitola 3 a dále) je pak již pozornost zúžena přímo na využití metod data miningu ve vzdělávání a analytiky učení v kontextu systémů typu LMS. V empirických kapitolách (4 až 6) je pak věnována pozornost specificky datům pocházejícím ze LMS Moodle na Filozofické fakultě Masarykovy univerzity.

## 1.2. E-learning a systémy pro řízení výuky

Pokud bychom v kontextu (české) pedagogiky hledali oblast, která se specificky věnuje využívání digitálních technologií, pak by se zřejmě jako první nabízela oblast označovaná termínem **technologie vzdělávání** (*technology of education*, resp. *educational technology*)<sup>10</sup>. Průcha (2000, 2005) chápe technologii vzdělávání jako jednu z disciplín, která tvoří obsahovou náplň pedagogiky jakožto edukační vědy. Tuto disciplínu je pak dle Průchy (srov. Průcha 2000; Průcha, Walterová, & Mareš, 2003) možné chápat ve dvou pojetích: V užším pojetí se chápe jako „teorie o využívání různých technických prostředků ve vyučování a učení“, v širším pojetí je pak vnímána jako „teorie o racionalizované a efektivní organizaci učení a vyučování, založená na psychodidaktických a ergonomických poznatcích o učení, a se zapojením technických prostředků výuky“ (Průcha, 2000, s. 120). Jak sám Průcha zároveň zmiňuje, obdobným způsobem chápe tento pojem například i Maňák (1994, s. 32), který hovoří o pedagogickém oboru určujícím racionální zásady didaktické práce a zaměřujícím se na optimální podmínky průběhu výuky a nejúčinnější metody či prostředky k dosažení vzdělávacích cílů. Obdobné didakticky orientované hledisko bychom našli i u Kalhousa a Obsta (Kalhous & Obst, 2002). Ve zmiňovaném širším pojetí se pak dle Průchy (2000) tato pedagogická disciplína odráží v tom, co bývá v zahraničním kontextu pojmenováváno jako *instructional design* a co Průcha překládá souslovím „plánování optimálního výukového prostředí“.

Ač Průcha a ostatní výše zmiňovaní autoři nepochybně odkazují k existující oblasti pedagogiky a do značné míry vystihují význam anglických označení *technology of education* a *educational technology*, domnívám se, že význam pojmu *educational technology* nevystihují v jeho úplnosti. Předně, obě pojetí zmiňovaná Průchou se vztahují primárně spíše k didaktice než pedagogice jakožto mnohem širší vědní disciplíně. V obou pojetích jde primárně o využívání technických prostředků ve výuce, přičemž užší pojetí Průcha (2000) explicitně spojuje s pojmem didaktická technika. Tím je ovšem poněkud opomenuta (zvláště v zahraničí) relativně široká oblast výzkumu digitálních technologií v oblasti vzdělávání, která se moderními technologiemi ve vzdělávání zabývá v širším smyslu než pouze ve smyslu didaktického prostředku. Tento pohled v českém kontextu reprezentují a snaží se zdůrazňovat např. Arnseth, Erstad, Juhaňák a Zounek (2016), když hovoří o nových výzvách

---

<sup>10</sup> Jako ekvivalent anglického *educational technology* se rovněž používá překlad „vzdělávací technologie“ či „technologie ve vzdělávání“. Tyto pojmy jsou však velmi často používány v jiném významu než Průchova „technologie vzdělávání“ (srov. Průcha 2000; Průcha, Walterová, & Mareš, 2003), přičemž mají blíže spíše k tomu, co níže označuji termínem „e-learning“.



výzkumu digitálních technologií v pedagogice a představují příklady výzkumů zaměřujících se především na mimoškolní prostředí. Zároveň upozorňují, že v současném (zvláště zahraničním) pedagogickém výzkumu již nejsou moderní technologie považovány pouze za didaktické pomůcky a jejich role ve vzdělávání je zkoumána v mnohem širším kontextu a v mnoha různých souvislostech.

Na druhé straně oblast označovaná jako technologie vzdělávání bývá v některých případech chápána natolik široce, že paradoxně ztrácí své zaměření na digitální technologie. Průcha (2000) sice ve svém širokém pojetí ještě explicitně uvádí technické prostředky a jejich zapojení do výuky, podíváme-li se však na vymezení Maňáka (1994), pak již vlastně není řeč specificky o informačních a komunikačních technologiích či technologických prostředcích. Místo toho je řeč o metodách a prostředcích zcela obecně. Toto velmi obecné pojetí pojmu technologie vzdělávání přitom není ojedinělé, nýbrž se s ním lze setkat i v řadě zahraničních zdrojů. Např. Aggarwal (2014) uvádí přehled dvaceti pěti různých definic pojmu technologie vzdělávání (*educational technology*), přičemž v žádné z těchto definic není zmíněno specifické zaměření na problematiku využívání moderních technologických prostředků ve vzdělávání<sup>11</sup>. V takovém pojetí se však oblast označovaná jako technologie vzdělávání nevěnuje problematice (digitálních) technologií jakožto specifickému tématu, a tudíž neodpovídá té oblasti pedagogického výzkumu, pro kterou je charakteristické právě to, že tematizuje problematiku digitálních technologií ve vzdělávání.

Z výše uvedených důvodů se domnívám, že oblast či disciplína označovaná v českém kontextu jako technologie vzdělávání není vhodným východiskem této práce. Místo toho pracuji s pojmem e-learning a vycházím z výzkumné oblasti, která tímto pojmem buď bývá přímo označována, anebo s ním (či jeho ekvivalenty) nějakým způsobem pracuje. V následujících podkapitolách tak nejprve představím pojem e-learning jako takový (včetně souvisejících pojmů relevantních pro tuto práci), a následně zaměřím pozornost přímo na systémy pro řízení výuky (LMS), jakožto specifický typ online vzdělávacích systémů, na něž se předkládaná disertační práce zaměřuje.

---

<sup>11</sup> Aggarwal (2014) ve své publikaci rovněž rozlišuje mezi pojmem *technology of education* a *technology in education*, což by bylo možné odpovídajícím způsobem převést do češtiny jako *technologie vzdělávání* a *technologie ve vzdělávání*. Technologie vzdělávání pak odkazuje k široké oblasti nezaměřující se pouze na problematiku (digitálních) technologií, zatímco technologie ve vzdělávání odkazuje přímo k využívání technologických prostředků ve vzdělávání.

### 1.2.1. E-learning

Pojem e-learning lze považovat zároveň za relativně nový i relativně starý. Na jedné straně se samotné slovo e-learning objevilo teprve koncem minulého tisíciletí. Konkrétně je za původce tohoto termínu považován Jay Cross, který jej začal využívat v roce 1998 (viz Corbeil & Corbeil, 2015). Na druhou stranu, jak poukazuje Zounek (2009), v jistém smyslu je možné o e-learningu hovořit jako o něčem, co už má relativně dlouhou historii: „Ač je e-learning typicky chápán jako ryze současný koncept, jeho počátky můžeme najít už zhruba v šedesátých letech minulého století“ (s. 24).

Je to dáno tím, že e-learning navazuje na relativně dlouhou řadu více či méně souvisejících termínů a pojmů, které e-learningu předcházely. Ať již jde o pojmy jako *web-based learning* či *web-based instruction*, které se začaly objevovat primárně v souvislosti s postupně se rozšiřující dostupností internetu a webu v 90. letech 20. století či o pojmy jako *computer-based training*, *computer-assisted instruction* či *computer-managed learning*, které lze datovat až do 60. let 20. století. Zároveň je možné jít ještě dále a vnímat e-learning jako oblast přímo navazující na tradici distančního vzdělávání, které samozřejmě existovalo dávno před internetem a moderními počítači, přičemž bylo realizováno prostřednictvím dobových formátů a komunikačních prostředků – od televize a rádia, přes audio a video pásy, až po běžnou korespondenci (Corbeil & Corbeil, 2015). Tuto historickou či spíše vývojovou návaznost oblasti e-learningu na oblast distančního vzdělávání akcentuje např. Thompson (2007), který zdůrazňuje, že oblast, na kterou se v současnosti odkazuje pomocí termínu e-learning, je ve skutečnosti součástí praxe vzdělávání již dlouhou dobu a stejně tak má dlouholetou tradici v rámci budování pedagogických teorií a rozvoje pedagogického výzkumu.

Přesto Thompson (2007) zároveň upozorňuje, že spolu se zavedením a rozšířením nového termínu *e-learning* došlo v této oblasti do určité míry k zapomenutí výše zmíněných historických kořenů a k určitému odtržení od mnoha let předchozího výzkumu v kontextu distančního vzdělávání. Toto odtržení se přitom částečně promítá i do samotného způsobu chápání pojmu e-learning, kde lze v základu rozlišit dva hlavní přístupy.<sup>12</sup> V prvním a rozšířenějším pojetí je e-learning chápán jako určitý specifický typ vzdělávacího procesu či forma vzdělávání, v druhém pojetí pak tento pojem slouží k označení určité oblasti výzkumu a vzdělávací praxe, která se zabývá problematikou digitálních technologií a jejich využitím ve vzdělávacím kontextu.

---

<sup>12</sup> Účelem této práce není podrobná analýza pojmu e-learning a jeho vymezení, proto se zde uchyluji k určitému zjednodušení (ovšem opodstatněnému, jak věřím). Podrobnější zmapování pojmu e-learning a různých aspektů jeho vymezení podává v českém kontextu např. Zounek (2009).

Prvnímu pojetí odpovídá v českém kontextu například definice e-learningu v Pedagogickém slovníku (viz Průcha, Walterová, & Mareš, 2009, s. 66), kde je e-learning vymezován jako „typ učení, při němž získávání a používání znalostí je distribuováno a usnadňováno elektronickými zařízeními“. Maněna et al. (2015, s. 33) pak místo o typu učení (jako Pedagogický slovník) hovoří spíše o e-learningu jako o specifickém způsobu vzdělávání. A to konkrétně takovém, který „využívá moderní informační a komunikační technologie k předávání výukového obsahu, komunikaci účastníků vzdělávání a k řízení výukového procesu“. Obdobně i Klement a Dostál (2018) hovoří o e-learningu jako o určité formě vzdělávání. Vymezení Kopeckého (2006, s. 6) pak zdůrazňuje to, že pojem e-learning označuje samotný proces využívání moderních technologických prostředků:

*E-learning je v podstatě jakékoli využívání elektronických, materiálních a didaktických prostředků k efektivnímu dosažení vzdělávacího cíle s tím, že je realizován zejména/nejenom prostřednictvím počítačových sítí.*

Druhé pojetí pojmu e-learning není v českém kontextu příliš obvyklé, a i v zahraničních zdrojích je výrazně méně zastoupeno než pojetí první. Přesto lze zmínit např. výše uvedeného Thompsona (2007), který považuje e-learning vesměs za „modernější“ označení té oblasti pedagogiky, která se zabývá distančním vzděláváním. Za významný příspěvek k pojetí e-learningu jakožto specifické výzkumné oblasti lze pak považovat publikaci editovanou Conolem a Oliverem (2007), podle kterých je e-learning termín využívaný k označení širokého okruhu výzkumných a rozvojových aktivit souvisejících s využíváním technologií ve vzdělávání<sup>13</sup>. Tato oblast se přitom nezaměřuje pouze na využívání technologií ve výuce, jako je tomu u oblasti technologií vzdělávání vymezené výše, nýbrž pokrývá širokou škálu výzkumných témat. Od těch, které se zaměřují primárně na samotné technologie, přes ty, jež se zaměřují na dopad technologií na výuku a učení, až po ty, které si pokládají otázky širšího sociokulturního rázu (Conole & Oliver, 2007).

Nutno však zároveň spolu s Conolem a Oliverem (2007) upozornit, že pro tuto výzkumnou oblast, kterou zde spolu s uvedenými autory označují termínem *e-learning*, se v odborné literatuře využívá i řada dalších označení. Lze zmínit např. obecné označení informační a komunikační technologie (*information and communication technologies – ICT*) případně specifičtěji ICT ve vzdělávání, ale také učební technologie (*learning technology*) či vzdělávací technologie (*educational technology*), anebo do češtiny hůře přeložitelné termíny jako technologiemi podporované učení (*technology-enhanced learning – TEL*).

---

<sup>13</sup> Konkrétně: „E-learning is the term most commonly used to represent the broader domain of development and research activities on the application of technologies to education.“ (Conole & Oliver, 2007, s. 4)

Jak je patrné, terminologie je zde značně komplikovaná a nejednotná. Již jsem poukázal na to, že např. anglický termín *educational technology* se do češtiny někdy překládá jako *technologie vzdělávání* a je využíván ve smyslu prezentovaném Průchou (2000) či Maňákem (1994). Jindy je však překládán spíše jako *vzdělávací technologie* či *technologie ve vzdělávání* a odkazuje spíše k tomu, co je zde představeno jako jedno z pojetí pojmu e-learning. Někde na pomezí těchto dvou pojetí se pak navíc pohybuje definice pojmu *educational technology*, jak ji představují Januszewski a Molenda (2008), kteří tuto oblast vnímají jako výzkum či studium a zároveň etickou praxi podpory učení a zlepšování výkonu vytvářením, používáním a řízením vhodných technologických procesů a zdrojů.

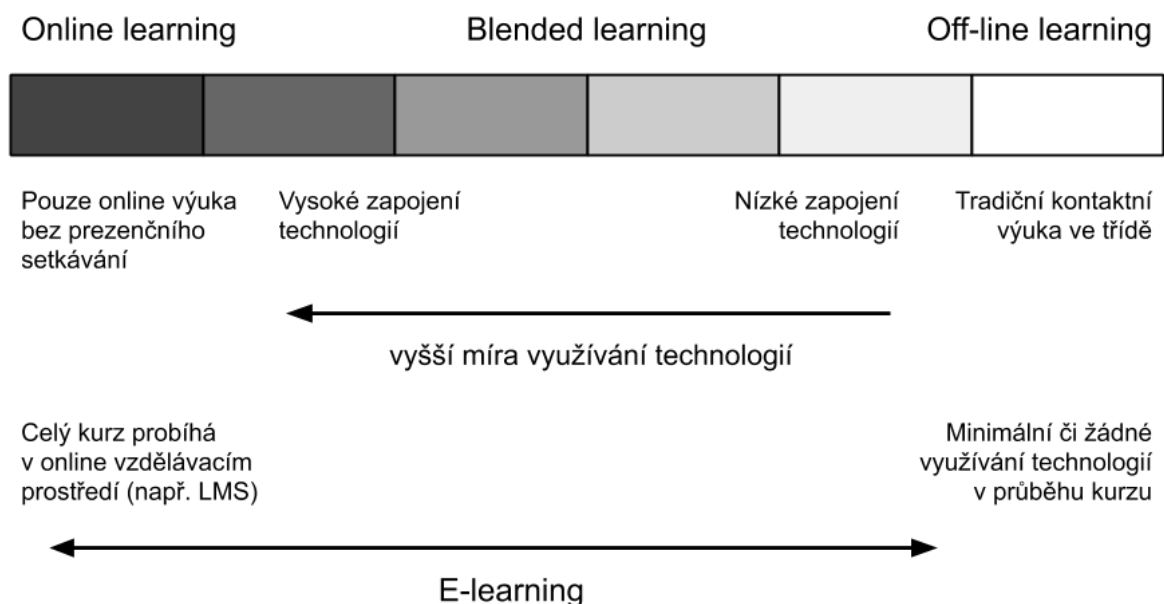
Za určitou kombinaci obou výše nastíněných přístupů k vymezení pojmu e-learning lze považovat pojetí e-learningu, jak jej dlouhodobě prezentuje Zounek (srov. Zounek, 2009; Zounek & Sudický, 2012; Zounek et al., 2016). Ten akcentuje jednak to, že pojem e-learning zahrnuje teorii a výzkum a může tak být vnímán jako vymezení určité oblasti pedagogiky jakožto vědy, jednak i to, že je pojem e-learning používán k označení určitého způsobu vzdělávání či konkrétního vzdělávacího procesu, v rámci kterého jsou v nějaké míře využívány informační a komunikační technologie. Konkrétně:

*E-learning v našem pojetí zahrnuje jak teorii a výzkum, tak i jakýkoli vzdělávací proces s různým stupněm intencionality, v němž jsou používány digitální technologie. Způsob využívání nástrojů digitálních technologií (ICT) a dostupnost učebních materiálů jsou závislé především na vzdělávacích cílech a obsahu, charakteru vzdělávacího prostředí, etických principech, potřebách i možnostech všech aktérů vzdělávacího procesu (Zounek et al., 2016, s. 34–35).*

Tuto definici e-learningu považuji v tomto textu za výchozí bod, jelikož jsem přesvědčen, že obě výše nastíněná pojetí jsou relevantní a v odborných zdrojích z této oblasti využívaná. Tudíž by nebylo možné vycházet z takové definice, která by jedno z těchto pojetí zcela opomíjela. V rámci samotného textu práce pak podle daného kontextu akcentuji jeden či druhý aspekt této definice podle toho, zda hovořím o výzkumné oblasti, anebo o samotném vzdělávacím procesu. Při vymezení oblasti analytiku učení a data miningu ve vzdělávání v části 1.1 (viz obrázek 2) pak mám přirozeně na mysli e-learning jakožto výzkumnou oblast, jejíž část se překrývá s oblastí data science a vytváří tak průnik, který vymezuje data mining ve vzdělávání a analytiku učení. Termíny jako ICT ve vzdělávání, vzdělávací technologie či technologiemi podporované učení přitom pro účely této práce chápu jako vesměs synonymní s termínem e-learning.

### 1.2.1.1. Online learning a blended learning

V návaznosti na přiblížení a vymezení pojmu e-learning je třeba pro účely této práce vymežit ještě dva související pojmy. Pojem **online learning** budu chápat jako ekvivalent českého pojmu online vzdělávání (případně online učení či online výuka) a budu jím rozumět takové vzdělávání, které probíhá výhradně v online prostředí. Tzn. například studium kurzů v online vzdělávacím prostředí, u kterých celý kurz a veškeré jeho součásti probíhají v daném online prostředí a nedochází tak k žádné formě prezenční výuky. Opak online vzdělávání je pak možné nazývat off-line vzděláváním (*off-line learning*), častěji však tuto formu vzdělávání najdeme v odborných zdrojích pojmenovanou jako „tradiční“ vzdělávání resp. výuka. Tímto označením je přitom myšlena taková forma vzdělávání, která je založená na tradičních výukových metodách ve smyslu kontaktní výuky. Pojmem **blended learning** (někdy též *b-learning*)<sup>14</sup> je pak myšlena kombinace obou výše uvedených forem, tzn. kombinace online a tradičního (off-line) vzdělávání (srov. Anderson, 2008; Mason & Rennie, 2006; Zounek et al., 2016). Vztah mezi jednotlivými pojmy pak naznačuje obrázek níže (viz obrázek 3).



Obrázek 3: Schéma naznačující vztah mezi pojmy *online learning*, *blended learning*, *off-line learning* a *e-learning* (dle Mason & Rennie, 2006, s. 14).

<sup>14</sup> Přidržuji se původního anglického označení místo českých variant jako smíšené či hybridní vzdělávání.

Jak je z obrázku výše patrné, míru zapojení digitálních technologií je třeba chápat jako škálu, na které pojmy online learning a off-line learning (resp. tradiční vzdělávání) tvoří pouze krajní body. Na levém kraji škály tak máme online vzdělávání, které probíhá zcela prostřednictvím digitálních technologií (typicky online kurz), zatímco na pravé straně škály máme off-line vzdělávání probíhající tradičně v prostředí školní třídy a bez využití či s minimálním využitím digitálních technologií<sup>15</sup>. Mezi těmito krajními body se však nachází poměrně velký prostor, kde může docházet k využití digitálních technologií v různé míře, přičemž právě tento prostor je označován pojmem blended learning. Pod pojem blended learning tak může spadat řada různých způsobů kombinace online a off-line výuky, a to jak co se týče kvantitativního zastoupení jednotlivých forem (např. 25 % prezenční výuka, 75 % studium v online výukovém prostředí), tak co se týče způsobu kombinace či následnosti jednotlivých forem výuky. Zounek et al. (2016) v tomto ohledu představují čtyři základní modely blended learningu:

1. *Rotační model*. Jde o řízené a obvykle pravidelné střídání obou forem výuky, přičemž dominantní zde bývá kontaktní výuka. Na základě charakteru střídání lze dále rozlišovat různé typy rotačního modelu. Např. v případě rotace místností se obvykle střídá výuka v běžné a počítačové učebně, zatímco v případě tzv. převrácené třídy (*flipped classroom*) se střídá domácí příprava realizovaná online formou s prezenční výukou, která je zaměřena na navazující diskusi, skupinovou práci či řešení problémů.
2. *Flexibilní model*. V tomto modelu sice tvoří online forma hlavní osu vzdělávání, ale zároveň jsou flexibilně zakomponovány i prezenční setkání. A to ať již formou přednášek, seminářů či individuálních konzultací.
3. *Model „volné nabídky“*. Jde o situaci, kdy student prochází vzděláváním v tradiční podobě (např. na univerzitě) a k tomu má možnost vybírat si a absolvovat doplňující kurzy v online podobě.
4. *Obohacený virtuální model*. Online forma je dominantní, prezenční setkání obvykle proběhne pouze na začátku (příp. i na konci) a zbytek kurzu probíhá online.

---

<sup>15</sup> Pokud bychom byly striktní, pak v současnosti zřejmě není příliš časté, že by v rámci výuky nedocházelo k vůbec žádnému využití digitálních technologií (ať již na straně učitele či studentů). Přeci jen, například i takový data projektor spadá do kategorie digitálních technologií. Na druhou stranu by asi bylo obtížně obhajitelné, pokud bychom nazývali blended learningem takovou situaci, kdy celé vzdělávání probíhá formou tradiční kontaktní výuky, jen s tím rozdílem, že vyučující používá data projektor k zobrazení své prezentace.

Na závěr této části je třeba ještě explicitně upozornit na vztah mezi pojmem e-learning a blended learning. Přestože bývá někdy pojem blended learning považován za širší než pojem e-learning, jak naznačuje obrázek výše (obrázek 3), v této práci považuji e-learning za širší a zahrnující jak online vzdělávání, tak i všechny formy blended learningu (srov. Andrews & Haythornthwaite, 2007; Mason & Rennie, 2006; Zounek et al., 2016).

### 1.2.2. Systémy pro řízení výuky

Jako v rámci celé oblasti e-learningu a vzdělávacích technologií, panuje i v kontextu systémů pro řízení výuky či obecně různých typů online vzdělávacích systémů velká terminologická nejednotnost. Úkolem této části je proto vedle samotného vymezení pojmu *systém pro řízení výuky* rovněž terminologické vyjasnění dalších souvisejících pojmů. Nutno však zároveň upozornit, že vzhledem ke zmiňované terminologické nejednotnosti bude zde nastíněné pojetí jednotlivých pojmů nutně jen jedním z mnoha možných. V řadě zdrojů lze tak nalézt tyto pojmy používané ve více či méně odlišném smyslu.

Za do určité míry zastřešující obecný pojem lze považovat pojem **virtuální vzdělávací prostředí** (*virtual learning environment – VLE*)<sup>16</sup>. I když tento pojem není vždy chápán jako obecný<sup>17</sup>, jeho využívání pro značně širokou paletu různých vzdělávacích prostředí a systémů je důvodem, proč jej považuji za vhodného kandidáta pro zastřešující obecný pojem. Proto stejně jako např. Zounek a Sudický (2012) chápou virtuální vzdělávací prostředí jako obecný pojem, který zahrnuje všechna elektronická prostředí či online systémy uplatnitelné při podpoře vzdělávacího procesu, a to jak při podpoře procesu vzdělávání jako celku, tak při podpoře pouze některé ze složek výuky a učení (např. příprava, vedení, evaluace atd.).

Pojem virtuální vzdělávací prostředí tak ve výše uvedeném smyslu zahrnuje nejen systémy typu LMS, ale také řadu dalších typů vzdělávacích systémů jako např.: systémy pro správu e-portfolií, vzdělávací virtuální světy (*virtual worlds*) a multi-uživatelská virtuální prostředí (*multi-user virtual environments*), online sociální sítě využívané ve vzdělávání či nejrůznější druhy otevřených vzdělávacích prostředí (*open learning environment*). Pojem virtuální vzdělávací prostředí je pak v této práci považován za totožný s pojmy jako online vzdělávací prostředí či online učební prostředí (*online learning environment*), e-learningové

---

<sup>16</sup> V této práci používám překlad *virtuální vzdělávací prostředí*, který patří mezi nejpoužívanější. Lze se však setkat i s dalšími překlady, např.: *virtuální učební prostředí* či *virtuální výukové prostředí*.

<sup>17</sup> Lze zmínit např. Wellera (2007), který chápe VLE jakožto synonymum LMS, tzn. ve značně užším smyslu než tato práce. Jiným příkladem jsou pak Annetta, Foltaová & Klesathová (2010), kteří používají označení VLE primárně v kontextu 3D virtuálních světů.

prostředí/systém či e-learningová platforma (srov. Dias, Diniz, & Hadjileontiadis, 2014; Kats, 2010).

V kontextu virtuálních vzdělávacích prostředí a v souvislosti s vymezením systémů pro řízení výuky je zároveň vhodné zmínit tzv. **integrativní vzdělávací technologie** (*integrative learning technologies – ILT*). Tento pojem lze chápat jako označení pro širokou (a v čase proměnlivou) skupinu různých webových nástrojů, softwarových aplikací a mobilních technologií, které integrují technologické a pedagogické funkce a možnosti internetu s cílem usnadnit návrh, vývoj, realizaci a řízení online vzdělávání (Kitsantas & Dabbagh, 2010)<sup>18</sup>. Jde tedy o nejrůznější online nástroje, aplikace či systémy, které se mohou lišit svým účelem, funkcemi, složitostí či možnostmi implementace do výuky a učení, ovšem je pro ně charakteristické právě to, že jsou využívány či využitelné v procesu vzdělávání (srov. Zounek & Sudický, 2012). Kitsantasová a Dabbaghová (2010) přitom rozlišují následujících pět didaktických oblastí integrativních vzdělávacích technologií:

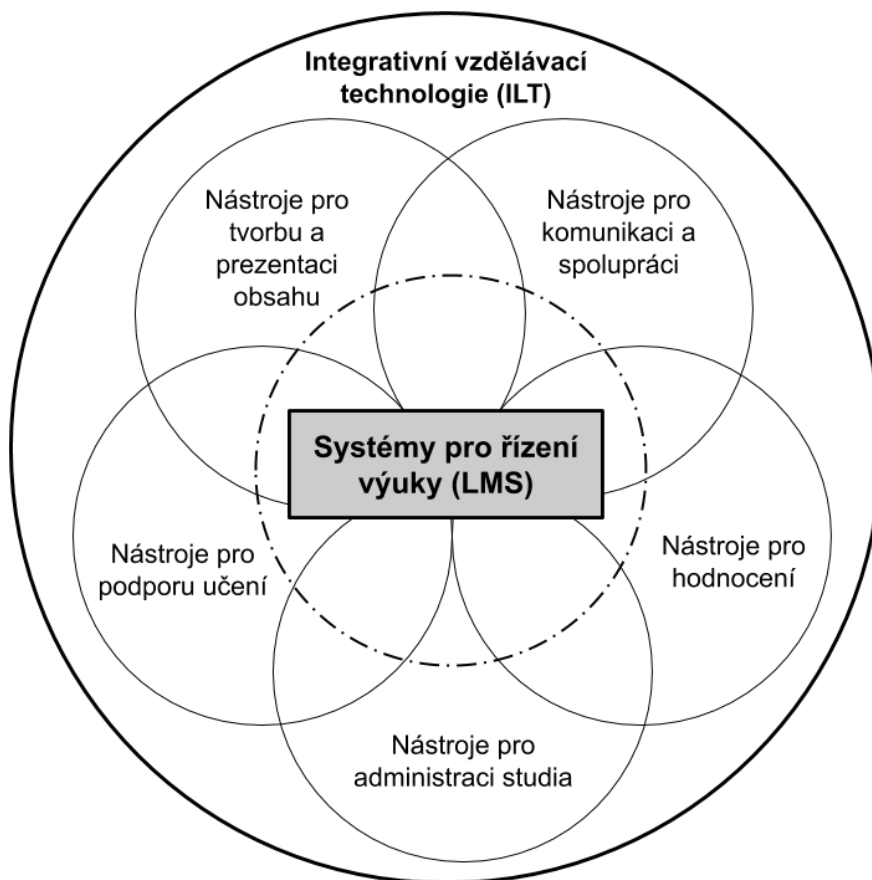
1. Nástroje pro komunikaci a spolupráci (*collaborative and communication tools*).
2. Nástroje pro tvorbu a prezentaci obsahu (*content creation and delivery tools*).
3. Nástroje pro administraci studia (*administrative tools*).
4. Nástroje pro podporu učení (*learning tools*).
5. Nástroje pro hodnocení (*assessment tools*).

S oporou o tyto základní didaktické oblasti pak Kitsantasová a Dabbaghová (2010) definují i **systémy pro řízení výuky** (*LMS*), které chápou jako podskupinu či speciální třídu integrativních vzdělávacích technologií spočívající v integraci či kombinaci nástrojů ze všech pěti výše uvedených didaktických oblastí. Názorně jejich pojetí představuje obrázek níže (obrázek 4), kde lze vidět, že systémy LMS jsou takovými systémy, které integrují všech pět základních kategorií nástrojů.

---

<sup>18</sup> Srov.: „a dynamic collection or aggregation of Web tools, software applications, and mobile technologies that integrate technological and pedagogical features and affordances of the Internet and the Web to facilitate the design, development, delivery, and management of online and distributed learning“ (Kitsantas & Dabbagh, 2010, s. 21).





Obrázek 4: Schéma naznačující vztah mezi ILT, LMS a jednotlivými kategoriemi nástrojů tvořících LMS (dle Kitsantas & Dabbagh, 2010, s. 24).

Obdobným způsobem jako výše zmínění autoři vymezují LMS i další odborné zdroje. Např. Kats (2010) chápe LMS jako označení pro plnohodnotné vzdělávací platformy, které jsou schopny podporovat současně vícero aspektů vzdělávacího procesu, a to od administrativních funkcí až po realizaci vzdělávacích kurzů či hodnocení studentů. Konkrétně pak za LMS považuje takový vzdělávací systém, který ve vzdělávacím kontextu poskytuje integrovanou podporu pro šest základních činností: tvorbu, organizaci, prezentaci, komunikaci, spolupráci a hodnocení. Podobně v českém kontextu vymezuje Zounek et al. (2016) LMS jako jeden z typů virtuálních vzdělávacích prostředí. Konkrétně pak takový, který se zaměřuje na vedení a organizaci učebního procesu skrze relativně přesně vymezené a učitelem vedené online kurzy, přičemž k naplnění této základní funkce integruje různé skupiny dílčích online nástrojů jako: nástroje pro prohlížení a vyhledávání na webu, nástroje pro synchronní a asynchronní komunikaci, nástroje pro podporu personalizovaného učení, nástroje pro sdílení zdrojů a výukového obsahu, nástroje pro tvorbu výukových objektů, nástroje pro administraci studia a nástroje pro hodnocení a evaluaci studentů a jejich práce.

Jak je z výše uvedeného patrné, přestože se autoři mírně liší ve výčtech jednotlivých kategorií nástrojů, obecně se shodují v tom, že systémy typu LMS lze chápat jako specifický typ virtuálních vzdělávacích systémů, který je charakteristický tím, že se pomocí integrace různých typů nástrojů snaží podporovat vzdělávací proces v jeho celistvosti. Co se týče terminologie, je v současnosti používání termínu LMS relativně ustálené.

Přesto je třeba zmínit, že řada autorů používá pro tento typ systémů rovněž označení VLE, které je však v této práci používáno v širším smyslu (viz výše). Spíše ve starších zdrojích se pak jako synonymum k termínu LMS používalo i označení řízené vzdělávací prostředí (*managed learning environment – MLE*), viz Mason a Rennie (2006). Naopak až do současnosti přetrvává využívání termínu systém pro řízení kurzů (*course management system – CMS*). A zatímco v některých zdrojích je tento pojem chápán jako synonymum k LMS, jiné zdroje oba pojmy rozlišují (např. Babo & Azevedo, 2012). CMS v takovém případě obvykle označuje pouze jednu z komponent LMS. Konkrétně tu, která slouží jako určité jádro LMS propojující jeho dílčí komponenty<sup>19</sup>. Zkratkou CMS však někteří autoři míní rovněž systém pro správu obsahu (*content management system*), který v kontextu LMS bývá označován také jako systém pro správu učebního obsahu (*learning content management system – LCMS*). Toto označení pak obvykle odkazuje pouze k té části LMS, která spočívá ve tvorbě obsahu kurzů (tj. nespádají tam např. nástroje pro administraci studia či nástroje pro hodnocení a zpětnou vazbu).

Nabídka systémů typu LMS je v současnosti velmi široká a univerzity přistupují k různým způsobům jejich správy a využívání. Od využívání proprietárního<sup>20</sup> LMS, který je zakoupen a následně spravován externí firmou, přes instalaci open-source LMS a jeho správu vlastními silami, až po vývoj vlastního řešení v rámci univerzity. Níže nabízím několik příkladů LMS, které jsou v současnosti ve světě využívány.

- Blackboard ([www.blackboard.com](http://www.blackboard.com))
- D2L Brightspace ([www.d2l.com](http://www.d2l.com))
- Canvas ([www.canvaslms.com](http://www.canvaslms.com))
- ILIAS ([www.ilias.de](http://www.ilias.de))
- Moodle ([moodle.org](http://moodle.org))

---

<sup>19</sup> V tomto pojetí zajišťuje CMS především přidělování odpovídajících oprávnění či rolí jednotlivým uživatelům systému. Tvůrcům kurzů tak dává přístup k nástrojům pro tvorbu kurzů, studentům umožňuje zápis do kurzů, tutorům dává přístup k nástrojům pro poskytování zpětné vazby a sledování pokroku studentů apod.

<sup>20</sup> Jako proprietární či uzavřený software je označován takový software, který nezpřístupňuje svůj zdrojový kód, a uživatelům tudíž neumožňuje jej studovat či upravovat (viz Havlová, 2003).

- Open edX (open.edx.org)
- OpenOLAT (www.openolat.com)
- Sakai (www.sakailms.org)
- Schoology (www.schoology.com)

V této práci se přitom zaměřuji primárně na systém Moodle<sup>21</sup>, který je spravován a využíván na Filozofické fakultě Masarykovy univerzity<sup>22</sup> pod označením Elf. Níže je proto systém Moodle v krátkosti představen.

### **1.2.2.1. LMS Moodle**

Původním autorem a vývojářem systému Moodle byl Martin Dougiamas a první verze LMS Moodle byla vydána v roce 2002<sup>23</sup>. Název systému je akronymem pro *Modular Object-Oriented Dynamic Learning Environment* neboli modulární objektově orientované dynamické vzdělávací prostředí. Filosofická a pedagogická východiska vývojářů LMS Moodle přitom podle jejich vlastních slov spočívají v sociálním konstruktivismu (Pedagogy, 2018; Philosophy, 2018).

Co se týče možností systému Moodle, pak nejen že pokrývá všechny základní kategorie integrativních vzdělávacích technologií, jak byly představeny v předchozí kapitole, nýbrž díky otevřenému kódu a široké komunitě uživatelů a vývojářů nabízí i obrovské množství specializovaných doplňkových modulů, které si může kdokoli nainstalovat<sup>24</sup>. Navíc systém

---

<sup>21</sup> Jelikož však různé systémy typu LMS sdílí řadu charakteristik i dílčích nástrojů (přinejmenším na úrovni výše uvedených pěti základních kategorií integrativních vzdělávacích technologií), měly by být metodologické postupy použité v této práci do značné míry použitelné i pro ostatní LMS. Stejně tak i zjištěné výsledky by měly být do určité míry platné napříč různými LMS.

<sup>22</sup> Je třeba dodat, že systém Elf je v rámci Masarykovy univerzity využíván i mimo Filozofickou fakultu. Určité množství kurzů v tomto systému pochází např. z Pedagogické fakulty, Přírodovědecké fakulty či Fakulty sociální studií, ale také třeba z Centra jazykového vzdělávání či ze střediska Teiresiás.

<sup>23</sup> Přibližně ve stejné době se zároveň na Masarykově univerzitě objevují první snahy o systematictější a koordinovaný rozvoj e-learningu. Konkrétně na Filozofické fakultě MU jsou první kroky v této oblasti iniciovány tehdejším proděkanem Josefem Krobem, což následně vede k nástupu prvního trvalého zaměstnance, jehož náplní práce je podpora e-learningu na fakultě. V dubnu 2003 je provedena první instalace systému Moodle na Katedře anglistiky a amerikanistiky. Tento systém byl pojmenován *e-doll (English Department On-Line Learning)* a do konce roku 2003 v něm bylo vytvořeno a provozováno 30 kurzů. Začátkem roku 2004 je spuštěna celofakultní instalace systému Moodle pod označením Elf (srov. Fictumová, 2004; Rambousek, 2004; Rambousek, Pytela, & Mikšík, 2005).

<sup>24</sup> Kompletní seznam doplňkových modulů lze najít na webových stránkách systému Moodle, konkrétně v databázi doplňkových modulů (*Moodle plugins directory* – moodle.org/plugins), kde v polovině roku 2019 bylo k dispozici cca 1600 doplňkových modulů.

Moodle v současnosti prochází poměrně rychlým vývojem s pravidelným vydáváním nových verzí, kdy je jednou za půl roku vydávána nová hlavní (*major*) verze<sup>25</sup> a každé dva měsíce nová menší (*minor*) verze. Je proto značně obtížné představit i jen základní možnosti tohoto systému v jeho celistvosti. Přesto, pokud vyjdeme z výčtu Maněny et al. (2015), můžeme základní možnosti systému Moodle shrnout následovně:

- vytváření tematicky, časově či jinak strukturovaných kurzů,
- spravování uživatelů a jejich zápisu do kurzů, včetně možnosti importu uživatelů (i kurzů) z externích databází či autentizace uživatelů skrze externí systémy,
- vytváření a používání různých typů testových úloh a testů jako celků,
- vkládání a přehrávání multimediálních souborů,
- tvorba interaktivních studijních materiálů a cvičení,
- komunikace a spolupráce studentů a učitelů v diskuzních fórech,
- společné (kolaborativní) vytváření dokumentů a dalších studijních materiálů (např. slovníků a databází),
- tvorba dotazníků či anket pro získání zpětné vazby,
- používání různých způsobů a škál hodnocení (automatické versus manuální hodnocení, bodové či slovní hodnocení, multikriteriální hodnocení atd.),
- sledování pokroku studentů, průběžné sledování jejich odpovědí a odevzdaných úkolů,
- propojení s externími aplikacemi a zdroji (např. aplikace Google či MS Office 365),
- a mnoho dalšího.

### 1.3. Data science a exploratorní metody analýzy dat

V předchozí kapitole jsem se věnoval e-learningu jakožto první ze dvou základních oblastí znázorněných v úvodním schématu (viz obrázek 2), které bylo použito při vymezení analytiky učení a data miningu ve vzdělávání. V této kapitole přesunu pozornost k druhé z uvedených oblastí, která byla označena jako **data science**.


Přestože vznik termínu *data science* lze datovat přinejmenším do 60. let minulého století, v dnešním slova smyslu se označení data science dostalo do širšího povědomí a začalo se výrazněji objevovat v odborné literatuře až kolem roku 2012. To dosvědčuje i graf níže (viz obrázek 5), který je vytvořen na základě počtů nalezených publikací obsahujících termín „data science“ v rámci webového vyhledávače odborných textů *Google Scholar*. K významnému

---

<sup>25</sup> Doplňme, že 18. listopadu 2019 byla vydána hlavní verze 3.8. Na 11. květen 2020 je pak plánováno vydání další hlavní verze, tj. 3.9 (viz Roadmap, 2019). Menší verze se pak číslují např. 3.8.1, 3.8.2 atd.

rozšíření tohoto pojmu pak zřejmě přispěl zvláště popularizační článek publikovaný Davenportem a Patilem (2012) v časopise *Harvard Business Review*, kde autoři označili profesi datového vědce (*data scientist*) za nejvíce „sexy“ povolání 21. století. A přestože někteří autoři vnímají pojem data science přinejmenším jako problematický, v současnosti jej lze považovat za relativně etablovaný. Důkazem je mimo jiné i to, že na řadě vysokých škol a univerzit ve světě dnes existují studijní programy nesoucí termín data science ve svém názvu<sup>26</sup>.

Počty nalezených publikací zmiňujících pojem data science v názvu dokumentu dle jednotlivých let



Obrázek 5: Počty nalezených výsledků v rámci Google Scholar zmiňujících pojem data science dle jednotlivých let. Výskyt hledaného termínu „data science“ je omezen na název dokumentu.

Rostoucí četnost využívání pojmu data science v posledních letech pramení, jak věřím, také z toho, že jde o užitečný pojem pro označení významného trendu na poli kvantitativně orientované vědy. Čím dál častěji totiž v různých vědních disciplínách dochází k tomu, že jsou k dispozici velké objemy dat, narůstají požadavky na výpočetní náročnost pro jejich analýzu a rozvíjí se využívání nových či méně obvyklých analytických metod, které jdou nad rámec „tradiční“ statistiky. Tyto nové analytické přístupy přitom obvykle vyžadují určitou formu

<sup>26</sup> Čtenář si může sám dohledat, kde všude jsou takové studijní programy nabízeny. Přesto alespoň upozorním na několik univerzit v evropském kontextu: *Eindhoven University of Technology*, *King's College London*, *Ludwig-Maximilians-Universität Munich*, *Maastricht University*, *Technical University Munich*, *University of Amsterdam*, *University of Barcelona*, *University of Bologna*, *University of Glasgow*, *University of Göttingen*, *University of Mannheim* či *University of Oslo*.

programování. V řadě vědních disciplín se tak postupem času objevily či se postupně objevují specializované výzkumné směry, které se zaměřují právě na tyto datové a výpočetně intenzivní oblasti, a které obvykle nesou přídomek „počítačový“, „výpočetní“ či „komputační“. Za v České republice již zavedenou výzkumnou oblast lze v tomto kontextu považovat např. počítačovou lingvistiku<sup>27</sup>. V zahraničním kontextu však existují obdobné směry i v řadě dalších disciplín, ačkoli v českém kontextu pro jejich označení zatím není k dispozici zvedený překlad (např.: *computational chemistry*, *computational biology*, *computational economics*, *computational neuroscience*, *computational cognition* či *computational psychology*, *computational sociology*, *computational history* a jiné<sup>28</sup>). V kontextu pedagogiky a vzdělávání lze oblasti jako data mining ve vzdělávání a analytika učení chápat jako určitou expresi tohoto obecného „celovědního“ trendu (tj. trendu existujícího napříč mnoha různými vědními obory).

Oblast označovaná jako data science se přitom neobjevila ve vzduchoprázdnu, nýbrž ji lze vnímat spíše jako důsledek obecného trendu, který trvá přinejmenším padesát let, jak upozornil Donoho v roce 2015 ve své prezentaci nazvané *50 years of Data Science* (později vydána v podobě článku, viz Donoho, 2017). Počátky data science lze přitom spatřovat především v práci Johna Tukeyho a v rozvoji exploratorních statistických metod, který počátkem 60. let minulého století Tukey nastartoval. V následujících kapitolách tak nejprve zaměřím pozornost na pojem exploratorní analýzy dat, který je stěžejním východiskem jak pro oblast data science, tak i pro data mining ve vzdělávání a analytiku učení (a tudíž i pro tuto disertační práci). Následně se přesunu přímo k pojmu data science a poskytnu jeho základní vymezení včetně nástinu kritiky, se kterou se využívání tohoto pojmu potýká. V závěru této kapitoly pak představím několik dalších pojmů, které hrají důležitou roli v současném diskurzu data science a exploratorních metod analýzy dat.

### **1.3.1. Exploratorní analýza dat jako součást kvantitativního výzkumu**

V kontextu českého pedagogického výzkumu je kvantitativně orientovaný výzkum velmi často ztotožňován se statistickým ověřováním hypotéz. Názorným příkladem může být vymezení kvantitativního výzkumu Švaříčkem a Šedřovou (2007, s. 25):

---

<sup>27</sup> Viz např. existující bakalářské a navazující magisterské studium Počítačová lingvistika na Filozofické fakultě Masarykovy univerzity ([www.muni.cz/bakalarske-a-magisterske-obory/24475-pocitacova-lingvistika](http://www.muni.cz/bakalarske-a-magisterske-obory/24475-pocitacova-lingvistika)).

<sup>28</sup> Srov. např. seznam souvisejících oblastí na stránce hesla *Computational science* v rámci anglické Wikipedie (viz [en.wikipedia.org/wiki/Computational\\_science](http://en.wikipedia.org/wiki/Computational_science)).

*Podstatou kvantitativního výzkumu je výběr jasně definovaných proměnných, sledování jejich rozložení v populaci a měření vztahů mezi nimi. Logické usuzování je v kvantitativním přístupu deduktivní: na počátku je existující teoretické tvrzení, které je na základě precizní operacionalizace převedeno do hypotéz a následně ověřováno. Výstupem výzkumu je ověření určité hypotézy či teorie.*

Takové pojetí kvantitativního výzkumu přitom není ojedinělé, ale naopak široce rozšířené a v české pedagogice silně zakořeněné. To potvrzuje i definice pojmu kvantitativní výzkum v Pedagogickém slovníku, kde je za cíl kvantitativního výzkumu považováno „objasňování jevů na základě vědecké teorie a ověřování hypotéz“ (Průcha, Walterová, & Mareš, 2003, s. 112). Zároveň, ačkoli se zde zaměřuji primárně na český pedagogický výzkum, je velmi pravděpodobné, že obdobná situace bude do větší či menší míry platit i v jiných zemích a jiných vědních disciplínách. Např. i Gavora (2008, s. 35), který je sice ve svém vyjádření o něco mírnější (hovoří pouze o „většině případů“), ve své slovenské metodologické publikaci uvádí: „Kvantitatívny výskum vo väčšine prípadov preveruje existujúcu pedagogickú teóriu (...) Najlepší spôsob, ako to urobiť, je vyvodzovať z teórie hypotézy a tieto potom vo výskume testovať (potvrdzovať alebo vyvracať)“. Toto výrazné zaměření pozornosti na statistické ověřování hypotéz se pak v českém kontextu odráží i v obsahu kvantitativně orientované metodologické literatury, kde je často výrazně více prostoru věnováno právě statistickým metodám testování a ověřování hypotéz než metodám pro explorační analýzu dat (srov. např. Disman, 2008; Hendl, 2012; Mareš, Rabušic, & Soukup, 2015).

Přitom kvantitativně orientovaná analýza dat je mnohem širší oblastí zahrnující mnoho dalších způsobů analýzy dat jdoucích nad rámec statistického testování hypotéz. Ostatně již přinejmenším od 60. let 20. století se v tomto kontextu začalo rozlišovat mezi dvěma základními přístupy k analýze dat. Toto rozlišení provedl a propagoval především Tukey (1962, 1977), jenž se vymezoval vůči klasické statistice a raději používal pojem analýza dat (*data analysis*), který vnímal jako širší<sup>29</sup>. Následně pak začal rozlišovat mezi tzv. **konfirmační analýzou dat** (*confirmatory data analysis*) a **exploratorní analýzou dat** (*exploratory data analysis*). Toto rozlišení lze přitom považovat za zcela zásadní, a to především proto, že vesměs odstartovalo následný rozvoj exploratorních statistických metod, který přetrvává až do dnešní doby a ke kterému dochází často právě pod hlavičkou nově zavedeného pojmu data science (Donoho, 2017). Tento rozvoj byl přitom výrazně poháněn na

---

<sup>29</sup> Konkrétně podle Tukeyho zahrnoval pojem analýza dat (mimo jiné) následující: a) různé postupy pro analyzování dat, b) techniky pro interpretaci výsledků takových postupů, c) způsoby plánování sběru dat tak, aby byla následná analýza jednodušší, přesnější či správnější, a poté i d) samotné postupy a výsledky (matematické) statistiky (srov. Tukey, 1962).

jedné straně rozvojem počítačů a jejich stále narůstajícími výpočetními možnostmi, na druhé straně pak také zásadním rozvojem kvalitativní metodologie (zvláště v kontextu sociálních věd), ke kterému došlo především v 80. a 90. letech 20. století. Jak v souvislosti s metodami a technikami exploratorní analýzy dat zmiňuje Hendl (2012, s. 23):

*Tyto techniky se vyvíjely paralelně se změnami v metodologických přístupech sociálních věd směrem ke kvalitativnímu a interpretativnímu myšlení. To klade důraz na heuristiky průzkumu dat a vytváření teorií, a ne pouze na asistenci při jejich přezkušování, jako tomu bylo v letech, kdy se statistici i výzkumníci soustředili na testování statistických hypotéz v duchu metodologie vědy Karla Poppera a jeho představ, že testy hypotéz jsou základem procesu vytváření teorií.*

Zatímco konfirmační analýzu dat lze vesměs ztotožnit s tím, co bývá označováno jako kvantitativní výzkum – totiž statistické ověřování hypotéz, exploratorní analýza dat označuje jiný přístup k analýze kvantitativních dat. Hendl (2012) popisuje exploratorní analýzu dat<sup>30</sup> jakožto skupinu statistických technik a zároveň specifický přístup k analýze dat, v rámci kterého je kladen důraz na grafický průzkum dat, využívání metod odolných vůči extrémním hodnotám a snahu nalézat v datech nové a dosud neznámé souvislosti a konfigurace. Zároveň exploratorní metody analýzy dat explicitně spojuje s dobýváním znalostí z dat resp. data miningem.

Exploratorní analýzu dat je však třeba odlišovat od toho, co někteří autoři (např. Chatfield, 1988; Everitt, 2002) označují jako **počáteční analýza dat** (*initial data analysis*), jejímž cílem je obvykle pouze provedení nezbytné přípravy a analýzy dat pro samotné testování hypotéz. Počáteční analýza dat se tak obvykle zaměřuje pouze na základní čištění dat či provedení transformace proměnných a následné ověření předpokladů statistických metod, které se plánují použít v rámci testování hypotéz (typicky například ověření normality dat apod.). Cílem exploratorní analýzy dat ovšem není pouze ověřování předpokladů pro navazující konfirmační analýzu, nýbrž jde o široké spektrum technik umožňujících hlubší porozumění datům, odhalování dosud neznámých souvislostí v datech a následně generování možných vysvětlení a (nových) hypotéz, jež mohou být následně ověřovány v rámci konfirmační analýzy. Behrens (1997) charakterizuje exploratorní analýzu dat s využitím následujících pěti bodů:

---

<sup>30</sup> Hendl používá označení „explorační analýza dat“, myslí tím však totéž, co je zde označováno jako „exploratorní analýza dat“, tj. ekvivalent anglického *exploratory data analysis* spojený se jménem Johna Tukeyho.



1. Exploratorní analýza dat klade důraz na věcné porozumění analyzovaným datům, snaží se zodpovědět obecnou otázku: O co v analyzovaných datech jde? Co analyzovaná data skutečně říkají?
2. Exploratorní analýza dat klade důraz na vizualizaci a grafickou reprezentaci dat.
3. Exploratorní analýza dat se zaměřuje na tvorbu předběžných či provizorních modelů a generování možných hypotéz, přičemž v tomto procesu postupuje iterativně v následujících krocích: specifikace modelu, analýza reziduí a následná respecifikace modelu.
4. Exploratorní analýza dat využívá a) robustní statistické techniky (tj. techniky odolné vůči odlehlým hodnotám), b) kombinaci více technik umožňujících zkoumat data různými způsoby, c) analýzu různých podskupin nacházejících se v datech.
5. V rámci exploratorní analýzy dat je uplatňován zároveň skeptický i flexibilní přístup, co se týče aplikace jednotlivých analytických metod a technik. Na jedné straně jsou jednotlivé metody a techniky kriticky vyhodnocovány, co se týče jejich možnosti přispět k porozumění analyzovaným datům, na druhé straně jsou v exploratorní analýze otevřené dveře zkoušení a testování nových potenciálně užitečných analytických metod a technik.

Sám Tukey pak vysvětloval exploratorní analýzu dat a její rozdíl oproti konfirmační analýze pomocí přirovnání k rozdílu mezi prací detektiva a soudu (Tukey, 1977). Dle Tukeyho je exploratorní analýza dat podobná práci detektiva. Úkolem detektiva není dát definitivní rozhodnutí o vině či nevině, nýbrž pouze hledat důkazy a získat pokud možno bohatou evidenci ukazující na vinu či nevinu podezřelého. Detektiv tak podrobně zkoumá místo činu, sleduje jednotlivé aktéry, generuje hypotézy o tom, jak mohla daná událost proběhnout apod. Úkolem detektiva je tedy sbírat faktické informace a nabízet jejich možné (nejpravděpodobnější) vysvětlení. Samotné rozhodnutí o vině či nevině podezřelého je však až záležitostí soudu. Ten pak dle Tukeyho odpovídá konfirmační analýze dat, resp. inferenční statistice a testování hypotéz. V této fázi už jsou fakta nasbírána a jsou prezentovány hypotézy o tom, jak se celá událost odehrála. Úkolem soudce je pak rozhodnout, zda jsou prezentovaná fakta dostatečně silná, aby podpořila hypotézu o vině či nevině podezřelého. Podobně v případě konfirmační analýzy máme předem danou hypotézu a našim úkolem je pomocí statistického testu zjistit, zda je tato hypotéza dostatečně silně podpořena daty.

Hendl (2012) pak při popisování exploratorní analýzy dat doplňuje, že tento přístup k analýze dat je důležitý především v těch typech výzkumů, kde předem neexistuje dostatečně

rozvinutá teorie, pomocí které bychom formulovali jednotlivé hypotézy, na jejichž základě bychom se pak zaměřili na konkrétní proměnné. Jde tak obvykle o výzkumy, které vychází z velkého množství potenciálně užitečných proměnných. Takové výzkumy tak teprve v průběhu samotné analýzy zjišťují, které proměnné jsou vlastně důležité a na které se případně zaměřit podrobněji v navazující analýze. Zároveň, jak Hendl (2012) také upozorňuje, je exploratorní analýza dat důležitá mimo jiné proto, že „umožňuje odhalit nečekané a na první pohled těžko zjistitelné vlastnosti dat, čímž se získává hlubší vhled do zkoumané problematiky“ (s. 118). To přitom může být přínosné zvláště v těch případech, kdy jsou odhaleny takové souvislosti, které prozatím existující teorie nezohledňovala.

### 1.3.2. Vznik, vymezení a kritika data science

Ačkoli je možné Tukeyho považovat za jednoho z prvních propagátorů myšlenky data science, sám toto označení nepoužíval, nýbrž hovořil o analýze dat (1962), resp. exploratorní analýze dat (1977). Za jednoho z prvních autorů, kteří pracovali přímo s termínem **data science**, bývá označován Peter Naur, který jej využíval ve své práci *Concise Survey of Computer Methods* (1974). Zatímco však Tukey nepoužíval označení *data science*, ale měl na mysli to, co se později pod tímto označením ustálilo, tak Naur sice používal termín *data science*, ale v poněkud odlišném smyslu, než jak je v současnosti chápán. Naur chápal data science jako vědu o tom, jak pracovat s daty, jakmile tato data byla jednou ustanovena či vytvořena (1974). Naopak otázka toho, co data reprezentují, spadá dle Naura do kompetence jiných disciplín či věd a tato otázka tak není součástí data science. Naurovo relativně úzké pojetí data science se však příliš neujalo. Jednak Tukey už před Naurem ukazoval spíše na potřebu širšího pojmu (primárně s ohledem na příliš úzce chápanou klasickou matematickou statistiku) a do svého vymezení pojmu analýza dat explicitně zahrnoval právě i záležitosti týkající se vzniku či tvorby dat (viz výše). Jednak dnešní pojetí data science vychází spíše z Tukeyho myšlenek, jak ukazuje např. Donoho (2017).

Z hlediska současného pojetí data science je zásadní rok 1977, kdy byla jako součást Mezinárodního statistického institutu (*International Statistical Institute – ISI*) ustanovena Mezinárodní asociace pro výpočetní statistiku (*International Association for Statistical Computing – IASC*), která ve svých stanovách navazovala spíše na Tukeyho široké pojetí nově se formující výzkumné oblasti. V rámci definice své mise pak IASC hovoří o potřebě propojení tradiční statistiky, moderní výpočetní techniky a znalostí odborníků v jednotlivých doménových oblastech (Jifa & Lingling, 2014). A ačkoli zde opět není využíván přímo termín *data science*, nýbrž, jak naznačuje název asociace, je řeč spíše o výpočetní statistice (*statistical computing* či *computational statistics*), tento důraz na propojení statistiky, informatiky

a specifických doménových znalostí se promítá i do současného chápání pojmu data science (srov. O'Neil & Schutt, 2013).

Dalším důležitým milníkem pro oblast data science byl až rok 1996, kdy bylo označení *data science* poprvé použito v názvu mezinárodní konference (Jifa & Lingling, 2014). Konkrétně šlo o konferenci odehrávající se v japonském městě Kóbe a pojmenovanou *Data science, classification, and related methods*. O dva roky později pak z této konference vychází stejně pojmenovaný sborník, kde Hayashi (1998) navazuje na myšlenky Tukeyho<sup>31</sup> a hovoří o data science jako o syntetizujícím konceptu, který sjednocuje statistiku, analýzu dat (v Tukeyho smyslu) a další související metody v těchto oblastech. Hayashi zároveň vnímá oblast data science jako specifickou v tom smyslu, že přináší jiný úhel pohledu než dosavadní tradiční a etablované metody výzkumu.

V roce 2001 Cleveland (2001) publikuje akční plán s názvem *Data Science: An Action Plan for Expanding the Technical Areas of the field of Statistics*, jehož cílem má být rozšíření znalostí technické práce s daty v rámci statistiky. Zároveň ale uvádí, že tento plán předpokládá natolik podstatnou změnu statistiky jakožto disciplíny, že onu novou disciplínu označuje jako data science. O rok později pak vzniká první časopis, který nese termín *data science* přímo ve svém názvu (*Data Science Journal*). Hned vzápětí, v roce 2003, vzniká druhý časopis obdobného zaměření (*Journal of Data Science*).

I přes výše naznačený relativně dlouhý historický vývoj, existující odborné časopisy a existující studijní programy na řadě univerzit po celém světě však doposud přetrvávají diskuze o vhodnosti pojmu data science a jeho vymezení. Na jedné straně jsou pokládány otázky týkající se přesnějšího vymezení oblasti označované jako *data science*, na straně druhé se diskutuje o oprávněnosti či legitimitě takové oblasti, zvláště s ohledem na již existující statistiku jakožto zavedenou disciplínu s dlouholetou historií (srov. např. Chambers, 1993; Breiman, 2001; Carmichael & Marron, 2018).

Pokud bychom hledali jednu dostatečně přesnou a zároveň široce přijímanou definici data science, tak skutečně budeme mít problém takovou definici najít. Přesto se domnívám, že lze z existujících zdrojů odvodit alespoň hrubou představu, která je přijatelná pro značné množství odborníků v dané oblasti. Konkrétně lze vyjít z již zmiňovaných kořenů data science, tj. ze slavného Tukeyho článku o budoucnosti datové analýzy (1962), a z formulace mise Mezinárodní asociace pro výpočetní statistiku, která byla zmiňovaná výše. Jak shrnuje

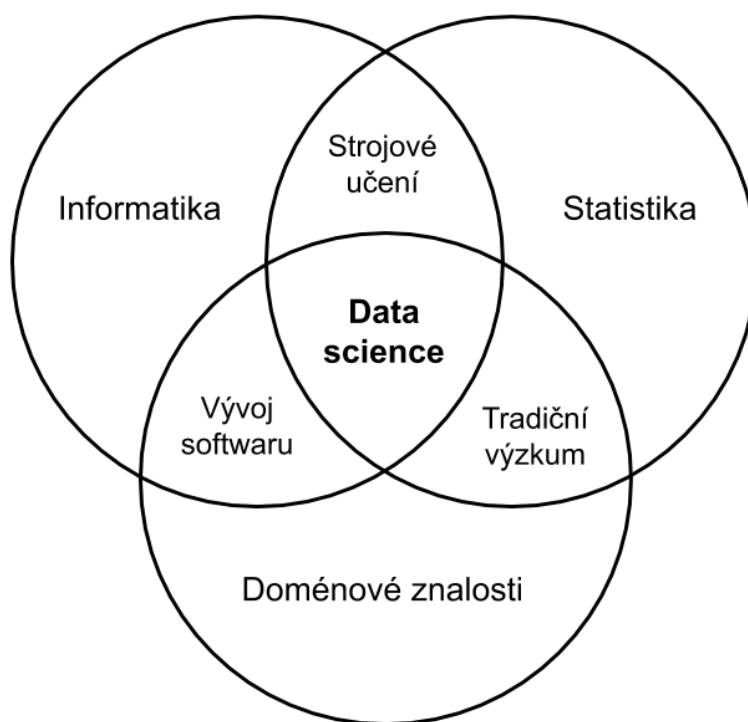
---

<sup>31</sup> Zvláště co se týče rozlišování mezi klasickou (matematickou) statistikou a oblastí označovanou jako analýza dat.

Donoho (2017), Tukey ve svém slavném článku identifikoval čtyři základní hnací síly vědy později pojmenované jako data science:

1. formální teorie statistiky jakožto disciplíny,
2. zrychlující se vývoj počítačů a zobrazovacích zařízení,
3. výzvy pramenící ze stále většího množství stále větších objemů dat dostupných v řadě výzkumných oblastí,
4. postupující důraz na kvantifikaci ve stále širším spektru vědeckých disciplín.

Vidíme, že podobně jako v rámci mise Mezinárodní asociace pro výpočetní statistiku se zde objevují tři základní aspekty či oblasti, které hrají roli při vymezení data science. Je zde statistika jakožto disciplína, ze které se oblast data science postupem času oddělila. Je zde oblast počítačů a moderních technologií, kterou by bylo možné zahrnout pod zastřešující disciplínu označovanou jako informatika (*computer science*). A jsou zde specifika vycházející z konkrétních vědních disciplín. Při využití Vennova diagramu lze tak data science vymežit právě pomocí těchto tří oblastí (obrázek 6). Nutno zároveň dodat, že obdobným způsobem (tj. tři zmiňované oblasti a znázornění pomocí Vennova diagramu) je vymežována oblast data science i v některých současných zdrojích (např. O'Neil & Schutt, 2013).



Obrázek 6: Vymezení oblasti data science jakožto průniku informatiky, statistiky a doménových znalostí.

Tři základní oblasti, jejichž průnik lze chápat jako vymezení data science, jsou tedy: informatika, statistika (resp. matematická statistika) a oblast doménových znalostí. A zatímco informatika a statistika nepotřebují bližší vysvětlení, v případě oblasti doménových znalostí se nabízí dvě základní pojetí. V prvním případě je oblast doménových znalostí chápána jakožto obecná oblast zahrnující široké spektrum poznatků z různých disciplín, které tak obohacují znalostní bázi data science jakožto obecné disciplíny. V druhém pojetí je pojem data science chápán úzce a vždy v návaznosti na konkrétní doménovou oblast či disciplínu. Místo jedné obecné disciplíny je tak v tomto pojetí vhodné hovořit spíše o různých výzkumných oblastech v rámci jednotlivých vědních disciplín. Toto pojetí odpovídá výše naznačenému trendu, kdy v řadě disciplín v současnosti existují specifické oblasti zaměřující se na využití moderních technologií a pokročilých statistických metod. Výše zmiňovaným příkladem byla např. oblast počítačové lingvistiky, kterou by pak v tomto pojetí bylo možné chápat jako data science v kontextu lingvistiky.

Určitou doplňující představu o data science pak na obrázku výše naznačují i dílčí průniky jednotlivých dvojic oblastí. Průnik mezi statistikou a informatikou je ztotožněn s oblastí strojového učení, průnik mezi informatikou a oblastí doménových znalostí je označen jako oblast vývoje (specializovaného) softwaru a průnik mezi statistikou a oblastí doménových znalostí je ztotožněn s tradičním (kvantitativně orientovaným) výzkumem. Při využití těchto dílčích průniků tak lze oblast data science chápat jako průnik tradičního výzkumu, strojového učení a vývoje softwaru.

Výše naznačené vymezení oblasti data science za využití Vennova diagramu má však jeden zásadní problém. Pokud bychom skutečně chápali data science jako průnik tří zmíněných oblastí, pak by oblast data science byla pouze dílčí specificky zaměřenou částí statistiky jakožto celku. To je ovšem v jednoznačném rozporu jednak s tím, jak je v současnosti tato výzkumná oblast vnímána, jednak s důvody, proč vůbec Tukey a ostatní apelovali na vznik zvláštní separátní disciplíny odlišné od statistiky. Hlavním důvodem totiž bylo to, že statistika byla často pojímána příliš úzce, a řada výzkumníků si uvědomovala potřebu širěji orientované disciplíny věnující se problematice analýzy dat. Vesměs všichni výše zmiňovaní autoři tak chápou data science jako širší ve srovnání s tradiční statistikou.

Příznačně to popisuje Chambers (1993), který píše o úzkém a širokém pojetí statistiky<sup>32</sup>. V širokém pojetí je statistika (tj. data science) chápána jako vše, co souvisí s analýzou

---

<sup>32</sup> V originále jsou využívány termíny *greater statistics* a *lesser statistics*, které lze vnímat jednak z hlediska šíře či velikosti (širší a užší či větší a menší), jednak z hlediska kvality (lepší a horší), což zároveň naznačuje Chambersovu pozici v diskuzi týkající se statistiky a data science.

a učením se z dat. Od plánování a sběru dat, až po prezentaci výsledků. Naopak v úzkém pojetí odpovídá statistika tomu, jak je běžně definována v odborných (statistických) textech, tzn. statistika jakožto akademická profese, která rozvíjí specifický typ (statistických) metod. A zatímco v širším pojetí je dle Chamberse statistika spíše inkluzivní a eklektická, v užším pojetí je spíše uzavřená a orientovaná především na matematicky založené techniky. Statistika v širokém pojetí často spolupracuje s dalšími disciplínami a bývá využívána i mimo akademické prostředí, přičemž se jí často věnují lidé, kteří nejsou profesionálními statistiky, zatímco v úzkém pojetí je statistika praktikována primárně v akademické sféře vystudovanými statistiky. Podobně například Carmichael a Marron (2018) vnímají pojem data science jednoduše jako reakci na úzké chápání statistiky. Pojem data science pro ně tudíž znamená pouze statistiku v širším pojetí.

S chápáním data science jako statistiky v širším pojetí ale zároveň souvisí i hlavní kritika směřovaná k této oblasti. Pokud jde totiž pouze o širší pojetí statistiky, pak je otázka, jestli je skutečně relevantní zavádět zcela nový pojem. A řada odborníků (zvláště statistiků) skutečně vyjadřuje nesouhlas či nepochopení, co se týče přidané hodnoty pojmu data science. Jak shrnuje Donoho (2017), pro řadu statistiků je termín *data science* pouze novým jménem pro statistiku. A stejně jako nemá smysl, aby např. fyzik používající ve své práci matematiku zaváděl nový termín typu „věda o číslech“, tak nemá smysl, aby člověk analyzující data zaváděl nový termín, když pro tuto činnost již po století existuje termín statistika.

Za určité východisko z nastíněných problémů by se dalo považovat to, že oblast data science nebude pojímána ani jako užší ani jako širší než statistika. Tzn., že data science nebude vnímána jako (pouze) část statistiky a stejně tak nebude statistika chápána pouze jako část širší oblasti pojmenované data science. Místo toho budou statistika a data science chápány jako dvě oblasti, které se v mnohém překrývají, ale zároveň každá z nich vede poněkud jiným směrem a zaměřuje větší pozornost na jiné problémy a jiné techniky analýzy dat. Donoho (2017) zmiňuje spíše v nevážném tónu definici odborníka z oblasti data science jakožto člověka, který je ve statistice lepší než jakýkoli programátor (softwarový vývojář), a zároveň je lepší v programování než jakýkoli statistik. A ačkoli takové vymezení nelze brát zcela vážně, do jisté míry vystihuje podstatu. Bylo by však vhodné v obdobném duchu doplnit, že odborník z oblasti data science je obvykle horší v programování než jakýkoli programátor a zároveň horší ve statistice než jakýkoli statistik. Jelikož se totiž odborník z oblasti data science zaměřuje jak na oblast statistiky, tak na oblast informatiky, nutně je pro něj náročnější dopracovat se v jedné či druhé disciplíně do takové hloubky jako člověk, který se specializuje jen na jednu z nich.

### 1.3.3. Vybrané pojmy související s oblastí data science

Jak bylo již naznačeno na obrázku výše (viz obrázek 2), v kontextu data science se lze setkat s několika více či méně souvisejícími oblastmi či pojmy. O statistice a exploratorní analýze dat (na zmiňovaném obrázku v podobě zkratky *EDA*) byla řeč v předchozích kapitolách, data mining a analytika budou podrobněji představy v kapitole 2, která se věnuje analytice učení a data miningu ve vzdělávání. Zde proto alespoň krátce zmíním a představím některé z dalších pojmů, které jsou pro kontext této disertační práce důležité, a které jsou běžně využívané v současném diskurzu data science a exploratorních metod analýzy dat.

Prvním takovým pojmem je pojem **big data** neboli „velká data“<sup>33</sup>. Pojem big data se přitom obvykle používá ve dvou základních významech. V prvním a výchozím významu odkazuje pojem big data k takovým datovým souborům, jejichž velikost či struktura je mimo schopnosti běžných databázových a datově-analytických nástrojů využívaných pro získávání, skladování, spravování či analyzování dat (srov. Manyika et al., 2011 či Hendl et al., 2014). V druhém významu se pak používá pojem big data k označení určité oblasti a souvisejících technických a analytických prostředků, které se zaměřují na práci s velmi velkými daty. Tak např. Hashem et al. (2015) vymezují pojem big data následovně:

*Big data označuje soubor technik a technologií, které vyžadují nové způsoby integrace za účelem odhalení skrytého a hodnotného potenciálu v obrovských datových souborech, které jsou různorodé, komplexní a mimořádně rozsáhlé. (Hashem et al., 2015, s. 100)*<sup>34</sup>

Podobně i Hilbert (2016) chápe pojem big data širěji než jen jako označení pro stále narůstající objem a kvalitu dostupných dat. Dle Hilberta odkazuje pojem big data především k možnostem a způsobům analýzy tohoto stále rostoucího množství dat. Rovněž ale také k výzvám, které taková velká data s ohledem na jejich analýzu otevírají. Charakter velkých dat pak bývá v anglicky psaných zdrojích velmi často pospisován pomocí několika (obvykle 3 až 5) klíčových slov začínajících na písmeno „V“. Konkrétně jsou zmiňovány (srov. Hashem et al., 2015; Hendl, 2014):

- *Volume* (objem) odkazuje ke stále většímu množství dat, která jsou v současnosti generována.

---

<sup>33</sup> Obvykle se i v češtině ponechává původní anglický výraz *big data*, přestože i český překlad začíná být postupně využíván. V některých publikacích se lze setkat i s překladem „veledata“ (např. Mayer-Schönberger & Cukier, 2014), ten je však využíván jen velmi ojediněle.

<sup>34</sup> „Big data is a set of techniques and technologies that require new forms of integration to uncover large hidden values from large datasets that are diverse, complex, and of a massive scale.“ (Hashem et al., 2015, s. 100).

- *Velocity* (rychlost) se týká především toho, jak rychle jsou generována nová data a jak rychle se data mění. Zároveň je tím ale myšleno také to, že v některých případech mohou data vyžadovat rychlé či dokonce okamžité zpracování.
- *Variety* (různorodost) odkazuje k široké škále různých druhů a formátů dat. Od strukturovaných (tabulka) po nestrukturované (text, obrázky, video), od sekvenčních dat po data síťového charakteru apod.
- *Veracity* (věrohodnost) poukazuje na to, že spolu s velkými daty přichází také otázky věrohodnosti dat. A to především co se týče jejich přesnosti, úplnosti, způsobu, jakým jsou generována apod.
- *Value* (hodnota) je do značné míry subjektivním aspektem, kterým se má obvykle na mysli to, že velké objemy dat mohou obsahovat potenciálně velmi hodnotné informace, které však zůstávají skryté, dokud nejsou z těchto dat získány či „vytěženy“.

Nutno zároveň podotknout, že oblast big data bývá velmi často spojována právě s oblastí data science. A to někdy až tak silně, že bývají oba pojmy ztotožňovány. Oblast data science pak v takových případech bývá vymezována jako oblast zabývající se analýzou velkých dat. Jak ale upozorňuje Donoho (2017), takové pojetí data science by bylo nejen neopodstatněné, ale především také neproduktivní, jelikož by nepostihovalo hlavní rozdíl mezi statistikou a data science. Přesto je ale třeba souhlasit s tím, že oblast big data má k oblasti data science velmi blízko, a to zvláště ve srovnání s tradiční statistikou. Jak uvádí Hendl et al. (2014, s. 129), „pracovníci, kteří se zabývají analýzou dat typu big data, mají v některých ohledech odlišné priority než například běžní statistici. Kromě statistiky musí znát problematiku ukládání a organizování dat a vyžaduje se od nich i znalost programování“.

Dalšími významnými pojmy v kontextu data science ale také big data jsou **strojové učení** (*machine learning – ML*) a širší oblast označovaná jako **umělá inteligence** (*artificial intelligence – AI*). Umělou inteligenci lze považovat za vědní disciplínu (obvykle vnímanou jako součást informatiky), která se zaměřuje na tvorbu počítačových systémů či strojů, které vykazují „inteligentní“ chování a jsou tak schopné řešit komplexní úlohy. Různých vymezení umělé inteligence lze však najít celou řadu, a to nejen v kontextu informatiky, ale také filosofie. Jednou z nejčastěji zmiňovaných je přitom definice, kterou představil Minsky v roce 1967, když v návaznosti na Turinga a Turingův test (Turing, 1950) vymezil umělou inteligenci jako vědu „o vytváření strojů nebo systémů, které budu při řešení určitého úkolu užívat takového postupu, který – kdyby ho dělal člověk – bychom považovali za projev jeho inteligence“ (cit. dle Mařík, Štěpánková, Lažanský et al., 1993). Z hlediska data science je pak



oblast umělé inteligence relevantní primárně proto, že v současnosti jednou z nejrychleji se rozvíjejících oblastí tohoto oboru je právě oblast strojového učení (Hostičková, 2014)<sup>35</sup>. Strojové učení je obvykle chápáno jako odvětví umělé inteligence (Awad & Khanna, 2015), které se zaměřuje na aplikaci algoritmů a statistických modelů za účelem automatizovaného odhalování skrytých vztahů a strukturálních vzorců v datech (Witten, Frank, & Hall, 2011). Jak je přitom z uvedeného vymezení patrné, je zde velký překryv se statistikou, oblastí big data, a především s data miningem.

V kontextu strojového učení se pak zvláště v posledních letech stal velmi populárním a často zmiňovaným pojem hluboké resp. **hloubkové učení** (*deep learning*). Tento pojem označuje metody strojového učení, které jsou využívány především v kontextu rozpoznávání obrazu či zpracování textu, a jež jsou založené na tzv. umělých neuronových sítích obsahující více vrstev neuronů mezi vstupní a výstupní vrstvou. Hlavní přínos této skupiny metod pak spočívá v tom, že dovolují systémům učit se více abstraktní koncepty (Dean, 2014)<sup>36</sup>.

## 1.4. Shrnutí kontextu disertační práce

Hlavním cílem této úvodní kapitoly bylo především usnadnit čtenáři vstup do problematiky analytiky učení a data miningu ve vzdělávání a zároveň jej do jisté míry připravit na následující kapitoly práce, které již vyžadují určité (alespoň základní) porozumění některým pojmům a souvislostem. Práce totiž předpokládá především čtenáře pohybujícího se primárně v kontextu pedagogiky či vzdělávání, který tudíž nemusí mít nutně přehled v oblastech technického či analytického charakteru, jež jsou však vzhledem k zaměření práce její nezbytnou součástí. Tato kapitola tak mířila především na takového čtenáře a snažila se: a) představit oblasti analytiky učení a data miningu ve vzdělávání, a tím zároveň nastínit základní zaměření této práce, b) ukotvit zmiňované oblasti a disertační práci jako celek do kontextu pedagogického výzkumu, a to jak po stránce věcné či tematické, tak po stránce metodologické.

---

<sup>35</sup> V současnosti dominantní paradigma umělé inteligence dle Hostičkové (2014) spočívá v tom, že místo aby bylo chování stroje explicitně naprogramováno (jak tomu dříve bývalo zvláště v souvislosti se systémy založenými na pravidlech, která do nich byla explicitně vkládána jejich tvůrci), využije se velké množství dat a určitý algoritmus, který systému dovolí se z těchto dat učit a vyvozovat si tak vlastní pravidla chování.

<sup>36</sup> Nutno zároveň upozornit, že tato oblast samozřejmě nemá nic společného s výzkumným směrem tzv. přístupů k učení (*approaches to learning*) zmiňovaným v českém kontextu např. Pabianem (2012), který je v kontextu pedagogiky jistě mnohem známější, a v rámci kterého se rozlišuje povrchové učení (*surface learning*) a hloubkové učení (*deep learning*), resp. povrchový a hloubkový přístup k učení.

Na základě obsahu jednotlivých kapitol lze shrnout, že analytiku učení a data mining ve vzdělávání je možné pro účely základního přiblížení považovat vesměs za identické oblasti, které se obě zaměřují na to, jak za využití specifických kvantitativních metod analyzovat data pocházející primárně z online vzdělávacích prostředí, a jak pomocí toho lépe porozumět učení a výuce v prostředích tohoto typu. V případě této disertační práce je pak věnována pozornost jednomu konkrétnímu typu online vzdělávacích prostředí, a to systémům typu LMS.

V rámci pedagogického výzkumu má analytika učení a data mining ve vzdělávání nejbližší oblastem označovaným jako technologie vzdělávání či e-learning. Z hlediska zaměření a řešených témat lze však analytiku učení a data mining ve vzdělávání ukotvit spíše v oblasti e-learningu, která chápe digitální technologie ve vzdělávání šířeji a nevnímá je pouze jako didaktické pomůcky. Zároveň je v této oblasti kladen větší důraz na teorii a výzkum. Vedle samotného vymezení pojmu e-learning pak byly představeny i další související pojmy, mezi kterými hraje hlavní roli blended learning neboli kombinace online vzdělávání a tradiční kontaktní výuky. Blended learning je přitom pro tuto práci stěžejní především proto, že se práce věnuje využití LMS Moodle na Filozofické fakultě Masarykovy univerzity, kde je (podobně jako na řadě jiných univerzit) systém Moodle využíván právě především v kombinaci s tradiční výukou v podobě seminářů či přednášek.

Z metodologického hlediska pak oblast data miningu ve vzdělávání a analytiky učení navazuje na tradici exploratorní analýzy dat, která se v současnosti zrcadlí především v oblasti označované jako data science. V oblasti kvantitativně orientovaného výzkumu totiž můžeme odlišit dva do značné míry odlišné přístupy, resp. dvě tradice či kultury kvantitativního výzkumu. V kontextu českého pedagogického výzkumu se dlouhodobě rozvíjela především jedna z těchto dvou kultur, totiž tzv. konfirmační analýza dat resp. statistické testování hypotéz. V celosvětovém kontextu je však v posledních letech patrný nárůst pozornosti i vůči oné druhé kultuře, totiž data science a exploratorním metodám analýzy dat. Oblast analytiky učení a data miningu ve vzdělávání tak můžeme do značné míry chápat jako projev tohoto širšího trendu v rámci pedagogiky a pedagogického výzkumu.

## 2. Analytika učení a data mining ve vzdělávání<sup>37</sup>

Po nastínění teoreticko-metodologického kontextu disertační práce v předchozí kapitole se tato kapitola věnuje přímo oblastem, které tvoří hlavní jádro práce. Cílem kapitoly je podání pokud možno komplexního přehledu jak o data miningu ve vzdělávání tak i o analytice učení jakožto specifických oblastech výzkumu a praxe v oblasti e-learningu a technologiemi podporovaného učení. Kapitola je přitom rozdělena do tří hlavních částí. V první části je zmapován historický kontext vzniku obou těchto relativně mladých oblastí a zároveň jsou nastíněny další výzkumné oblasti, které se významným způsobem podílely na vzniku a formování analytiky učení a data miningu ve vzdělávání. Druhá část se zaměřuje na podrobnější rozpracování obou oblastí jako takových, a to včetně jejich podrobného vymezení a následně představení souvisejících pojmů a konceptů, využívaných analytických postupů a metod či analyzovaných typů dat. Zároveň v této části dochází ke srovnání obou oblastí a jsou tak podrobněji popsány hlavní shody a rozdíly v jejich pojmání. Třetí část kapitoly je věnována přehledu dosavadních výzkumů v oblastech analytiky a data miningu ve vzdělávání. Jejím cílem je zmapovat a představit základní výzkumná témata, která jsou v těchto oblastech řešena a kterým je věnována největší výzkumná pozornost.

### 2.1. Vznik a historické kořeny

O vzniku výzkumné oblasti označované jako data mining ve vzdělávání (*educational data mining – EDM*) se asi nejčastěji hovoří ve spojení s roky 2008 a 2009. Je to dáno tím, že v roce 2008 proběhla první mezinárodní konference zaměřená specificky na data mining ve vzdělávání (*International Conference on Educational Data Mining*) a v roce 2009 pak vyšlo první číslo časopisu *Journal of Educational Data Mining* zaměřeného výhradně na tuto oblast. Jak ale naznačuje jeden z prvních článků publikovaných ve zmiňovaném časopise (Baker & Yacef, 2009), historické kořeny této oblasti jsou výrazně starší. Pokud bychom vyšli ze studie Romera a Ventury (2007), pak můžeme spatřovat první snahy a využití data miningu ve vzdělávání již od roku 1995<sup>38</sup>. V kontextu e-learningu a technologiemi podporovaného učení se však začala data miningu věnovat větší pozornost spíše až na přelomu tisíciletí. To se

---

<sup>37</sup> Části této kapitoly (primárně ty, které se věnují analytice učení) vychází z autorem publikované přehledové studie s názvem *Analytika učení: nový přístup ke zkoumání učení (nejen) ve virtuálním prostředí* (Juhaňák & Zounek, 2016) a publikované kapitoly v knize s názvem *Learning Analytics: Challenges and Opportunities of Using Data Analysis in Education* (Juhaňák & Zounek, 2019). Průběžné verze této části byly také prezentovány na několika národních konferencích (viz např. Juhaňák, 2013, 2014a a 2014b).

<sup>38</sup> Zde však šlo ještě o využití data miningu v kontextu „tradičního“ vzdělávání nikoli v souvislosti s online vzdělávacími systémy typu LMS či VLE, jelikož ty se začaly více rozšiřovat až o několik let později.

následně projevilo i v tom, že se téma data miningu ve vzdělávání začalo postupně objevovat v podobě specializovaných workshopů a seminářů na několika tematicky příbuzných konferencích<sup>39</sup> (Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018). Rostoucí zájem o téma data miningu v kontextu vzdělávání pak v roce 2005 vyústil v publikaci *Data Mining in E-learning* (2005), která se tak stala první knihou věnující se tomuto specifickému tématu. Zároveň bylo v roce 2005 poprvé použito označení *Educational data mining* přímo v názvu odborného workshopu zaměřujícího se na tuto oblast (Romero & Ventura, 2013).

Přesto lze právě v souvislosti s lety 2008 a 2009 hovořit o určitém vzniku, a to v tom smyslu, že přibližně v této době se začíná o data miningu ve vzdělávání hovořit jako o samostatné a svébytné výzkumné oblasti. Vedle již zmiňované první konference a prvního časopisu věnujících se tomuto tématu, lze za další důležitý milník považovat knihu *Handbook of educational data mining* (Romero, Ventura, Pechenizkiy, & Baker, 2010), která se jako první zaměřuje explicitně na oblast EDM. V následujícím roce pak byla založena mezinárodní společnost pro data mining ve vzdělávání (*The International Educational Data Mining Society*). Zároveň se tou dobou začínala vyčleňovat druhá z oblastí, kterým se věnuje tato práce, totiž analytika učení (learning analytics). V souvislosti s oběma zmiňovanými oblastmi se pak přibližně od roku 2014 postupně začíná objevovat hned několik odborných knih, které shrnuje tabulka níže (viz tabulka 1).

Tabulka 1: Přehled základních odborných knih věnujících se specificky problematice data miningu ve vzdělávání či analytice učení.

Rok	Oblast	Název knihy	Odkaz na zdroj
2005	EDM	<i>Data Mining in E-learning</i>	(Romero & Ventura, 2005)
2010	EDM	<i>Handbook of educational data mining</i>	(Romero, Ventura, Pechenizkiy, & Baker, 2010)
2014	EDM	<i>Educational Data Mining: Applications and Trends</i>	(Peña-Ayala, 2014a)
2014	LA	<i>Learning Analytics: From Research to Practice</i>	(Larusson & White, 2014)
2016	LA	<i>Developing Effective Educational Experiences through Learning Analytics</i>	(Anderson & Gavan, 2016)

<sup>39</sup> Šlo např. o konference *International Conference on Artificial Intelligence in Education* (AIED), *International Conference on Intelligent Tutoring Systems* (ITS) či *Annual Conference of the Association for the Advancement of Artificial Intelligence* (AAAI).

2016	EDM i LA	<i>Data Mining and Learning Analytics: Applications in Educational Research</i>	(ElAtia, Ipperciel, & Zaïane, 2016)
2016	EDM	<i>Educational Data Mining with R and Rattle</i>	(Kamath & Kamat, 2016)
2017	LA	<i>Big Data and Learning Analytics in Higher Education: Current Theory and Practice</i>	(Daniel, 2017)
2017	EDM i LA	<i>Big Data in Education: The digital future of learning, policy and practice</i>	(Williamson, 2017)
2017	LA	<i>Handbook of Learning Analytics</i>	(Lang, Siemens, Wise, & Gašević, 2017)
2017	LA	<i>Learning Analytics: Fundamentals, Applications, and Trends: A View of the Current State of the Art to Enhance e-Learning</i>	(Peña-Ayala, 2017)
2017	LA	<i>Learning Analytics Explained</i>	(Sclater, Learning Analytics Explained, 2017)
2017	LA	<i>Learning and Knowledge Analytics in Open Education</i>	(Lai & Lehman, 2017)
2018	LA	<i>Learning Analytics Goes to School: A Collaborative Approach to Improving Education</i>	(Krumm, Means, & Bienkowski, 2018)
2018	LA	<i>Learning Analytics in the Classroom: Translating Learning Analytics Research for Teachers</i>	(Lodge, Horvath, & Corrin, 2018)
2018	LA	<i>Learning Analytics in Higher Education: Current Innovations, Future Potential, and Practical Applications</i>	(Lester, Klein, Johri, & Rangwala, 2018)

---

O analytice učení jako svébytné oblasti zabývající se zkoumáním učení ve virtuálním prostředí se začíná hovořit na přelomu let 2010 a 2011, a to především z toho důvodu, že v roce 2010 publikoval Siemens na svém blogu zřejmě první definici analytiky učení, která se později stala všeobecně přijímanou v řadě odborných textů (srov. např. Ferguson, 2012a; Chatti et al., 2012; Siemens, 2013). V roce 2011 pak proběhla první mezinárodní konference zaměřená specificky na analytiku učení (*1st International Conference on Learning Analytics and Knowledge*) a zároveň byla založena společnost pro výzkum v oblasti analytiky učení (*Society for Learning Analytics Research*). Ve stejném roce byla také analytika učení poprvé zmíněna ve výroční zprávě *Horizon Report* (Johnson, Smith, Willis, Levine, & Haywood,

2011), čímž se tato oblast začala dostávat do širšího povědomí odborníků v kontextu e-learningu i vzdělávání obecně.

Analytice učení pak byla věnována výrazná pozornost i v následujících letech. V uvedené výroční zprávě *Horizon Report* se analytika učení nadále objevovala jako jeden z klíčových trendů ve vzdělávání (Johnson, Adams, & Cummins, 2012; Johnson et al., 2013; Johnson, Adams Becker, Estrada, & Freeman, 2014). Od roku 2012 se pak na analytiku učení začaly více zaměřovat i odborné časopisy a postupně vzniklo několik speciálních čísel věnovaných právě tomuto tématu. Jejich základní přehled podává následující tabulka (viz tabulka 2). V roce 2014 vychází první číslo nového časopisu zabývajícího se přímo analytikou učení (*Journal of Learning Analytics*) a vychází také první monografie zaměřená specificky na téma analytiky učení (Larsson & White, 2014). V roce 2017 se objevila řada dalších publikací zaměřujících se na analytiku učení, jak je patrné z tabulky výše (viz tabulka 1).

Tabulka 2: Vybraná speciální čísla odborných časopisů zaměřujících se na analytiku učení.

<b>Rok</b>	<b>Název časopisu</b>	<b>Číslo</b>	<b>Téma speciálního čísla</b>
2012	<i>Journal of Asynchronous Learning Networks</i>	Vol. 16, No. 3	Learning Analytics
2012	<i>Journal of Educational Technology &amp; Society</i>	Vol. 15, No. 3	Learning and Knowledge Analytics
2013	<i>American Behavioral Scientist</i>	Vol. 57, No. 10	Learning Analytics
2013	<i>Journal of the Learning Sciences</i>	Vol. 22, No. 4	Learning Analytics and Computational Techniques for Detecting and Evaluating Patterns in Learning
2015	<i>Journal of Universal Computer Science</i>	Vol. 21, No. 1	Learning Analytics
2015	<i>Computers in Human Behavior</i>	Vol. 47	Learning Analytics, Educational Data Mining and data-driven Educational Decision Making
2016	<i>Journal of Computer Assisted Learning</i>	Vol. 32, No. 3	Learning Analytics in Massively Multi-User Virtual Environments and Courses
2016	<i>Educational Technology Research and Development</i>	Vol. 64, No. 5	Exploring the Relationship of Ethics and Privacy in Learning Analytics and Design: Implications for the Field of Educational Technology

2017	<i>Interactive Learning Environments</i>	Vol. 25, No. 2	Learning Analytics
2017	<i>Zeitschrift für Hochschulentwicklung [Journal for Higher Education Development]</i>	Vol. 12, No. 1	Learning Analytics: Implications for Higher Education
2017	<i>New Directions for Higher Education</i>	Vol. 2017, No. 179	Learning Analytics in Higher Education
2017	<i>Journal of Educational Technology &amp; Society</i>	Vol. 20, No. 2	Learning Analytics in Technology Enhanced Language Learning
2017	<i>ASHE Higher Education Report</i>	Vol. 43, No. 5	Learning Analytics in Higher Education
2017	<i>Journal of Research in Innovative Teaching &amp; Learning</i>	Vol. 10, No. 2	Learning analytics in primary, secondary and higher education
2018	<i>International Journal of Innovation and Learning</i>	Vol. 23, No. 1	User Modelling and Learning Analytics
2018	<i>Journal of Educational Technology &amp; Society</i>	Vol. 21, No. 2	Trends and Research Issues of Learning Analytics and Educational Big Data
2019	<i>Interactive Learning Environments</i>	Vol. 27, No. 5-6	The new potentials for Intelligent Tutoring with learning analytics approaches
2019	<i>User Modeling and User-Adapted Interaction</i>	Vol. 29, No. 4	Learning Analytics and Personalised Support Across Spaces

### 2.1.1. Historické kořeny data miningu ve vzdělávání

Data mining jako takový, někdy označován také jako dobývání znalostí z databází (*knowledge-discovery in databases – KDD*)<sup>40</sup>, se začal výrazněji rozvíjet začátkem 90. let minulého století a postupem času se začal prosazovat v mnoha oblastech od akademického

<sup>40</sup> Nutno podotknout, že ačkoli mnozí autoři dnes chápou pojmy data mining a dobývání znalostí z databází jako vesměs synonymní (Gorunescu, 2011), jiní autoři je rozlišují a chápou data mining pouze jako jeden z kroků v rámci procesu dobývání znalostí z databází. Toto rozlišování obou pojmů vychází především z prací Fayyada (Fayyad, Piatetsky-Shapiro, & Smyth, 1996), podle kterého KDD odkazuje k celkovému procesu získávání užitečných znalostí z dat, kdežto pojem data mining odkazuje pouze ke konkrétnímu kroku v tomto procesu, kdy jsou aplikovány specifické algoritmy pro extrakci určitých vzorců z dat. V této práci se přikláním k první skupině autorů a považuji oba pojmy za synonymní.

výzkumu, přes soukromou sféru, až po různé specifické oblasti využití jako např. lékařství, geografie či internetová bezpečnost.

Data mining lze definovat více způsoby, např. Gorunescu (2011) uvádí následující definice:

- Automatické hledání vzorců (*patterns*) v obrovských databázích s využitím výpočetních technik z oblasti statistiky, strojového učení a rozpoznávání vzorců (*pattern recognition*).
- Netriviální extrakce implicitních, dříve neznámých a potenciálně použitelných informací z dat.
- Věda o získávání užitečných informací z velkých datových souborů nebo databází.
- Proces automatického objevování informací, identifikace vzorců a vztahů „skrytých“ v datech.

Vidíme, že všechny uvedené definice mají jedno společné, totiž že v rámci data miningu jde o práci s velkými datovými soubory, ve kterých jsou s využitím specifických výpočetních technik automaticky odhalovány doposud neznámé informace, vzorce či vztahy. Data mining přitom čerpá především ze tří hlavních oblastí, které propojuje a jejichž techniky a metody využívá. V první řadě se jedná o „klasičku“ **statistiku**, ve které data mining navazuje především na oblast exploratorní analýzy dat (viz kapitola 1.3.1). Zde data mining čerpá především základní popisné a explorační statistické a vizualizační techniky. Druhou oblastí, na které data mining staví, je **umělá inteligence** (*artificial intelligence*) a **strojové učení** (*machine learning*). Tyto oblasti propůjčují data miningu především různé techniky zpracování informací založené na pokročilém matematickém aparátu, jakož i sadu algoritmů umožňujících počítači „učit se“ z dat. V neposlední řadě pak data mining navazuje na **oblast databázových systémů** (*database systems*), kde využívá především technické poznatky o způsobech ukládání a uchovávání dat, struktuře dat a databází, data managementu apod.

Oblast data miningu ve vzdělávání, jakožto oblast zaměřující se na využití data miningu specificky ve vzdělávacím kontextu, pak vznikla především na základě snah o využití data miningu pro analýzu tzv. logů<sup>41</sup> či záznamů a interakci studentů v online vzdělávacích systémech (Baker & Yacef, 2009). Postupně se byly rozvíjeny stále nové možnosti využití data miningu v oblasti e-learningu a již v roce 2007 Castro a spol. hovoří o řadě směrů využití data miningu v oblasti e-learningu. Zmiňují např.: využití data miningu v oblasti hodnocení výkonu studentů, při evaluaci učebních materiálů a online kurzů či data mining zaměřený na

---

<sup>41</sup> Termín „log“ resp. „logy“ má v češtině dva významy. V prvním významu se tímto slovem označuje soubor či tabulka obsahující záznamy o činnosti (např. o činnosti uživatelů určitého systému), v druhém významu se slovem log odkazuje ke každému jednotlivému záznamu o činnosti, který je uložen ve zmiňovaném souboru.



detekci atypického učebního chování studentů (Castro, Vellido, Nebot, & Mugica, 2007). Tyto stále se rozšiřující možnosti využití nakonec vedly k ustanovení data miningu ve vzdělávání jakožto svébytné výzkumné oblasti.

### **2.1.2. Historické kořeny analytiky učení**

Analytiku jakožto obecný pojem je poměrně obtížné přesně vymezit. S tím, jak se tento pojem v průběhu posledních patnácti až dvaceti let dostal do širšího povědomí, začal totiž být používán v mnoha různých oblastech a kontextech (Van Barneveld, Arnold, & Campbell, 2012). Pojem analytiky tak najdeme nejen ve spojení s učením (*learning analytics*), ale také ve spojení s řadou dalších oblastí (např. *health analytics*, *news analytics*, *cultural analytics* apod.). Časté je také rozlišování analytiky podle účelu prováděných analýz (např. *predictive analytics*, *prescriptive analytics* či *action analytics*), nebo na základě spojení s konkrétní sadou analytických nástrojů (*google analytics*, *twitter analytics*, *facebook analytics* apod.). Někteří autoři se proto přiklánějí k názoru, že kvůli nadužívání tohoto pojmu je jakýkoli pokus o podání jeho dostatečně podrobné a netriviální definice předem odsouzen k nezdaru (Cooper, 2012a).

Pro účely této práce vycházím z obecně pojaté definice autorek Bienkowski, Feng a Means (2012), které vymezují analytiku v širokém smyslu jako využívání technik z počítačových věd, matematiky a statistiky pro extrakci užitečných informací z velkých objemů dat. Všimněme si přitom tří zásadních aspektů:

1. Analytika čerpá ze znalostí a dovedností jak z oblasti informatiky, tak z oblasti matematiky, a primárně statistiky a analýzy dat.
2. Cílem analytiky je získat informace, které pro nás budou užitečné při dalším plánování či jednání. Jde tedy o informace, které vedou k nějaké další akci (Cooper, 2012a; Picciano, 2012). Van Barneveld, Arnold a Campbell (2012) dokonce vyzdvihují pouze tento aspekt a definují analytiku jednoduše jako daty řízené rozhodování (*data-driven decision making*).
3. Analytika se zabývá velkými objemy dat, kdy nejsou neobvyklé ani datové sady o desítkách či stovkách milionů záznamů. Zde lze pak spatřovat určitý rozdíl oproti „tradiční“ statistice, která nepracuje příliš často s velmi velkými daty (tj. výše zmiňovaná oblast *big data*).

Do širšího povědomí se pojem analytiky dostal především na základě dvou oblastí: webové analytiky (*web analytics*) a podnikové analytiky (*business analytics* či *business intelligence*). Z nich zároveň čerpaly další specifické oblasti analytiky při vlastním vzniku a formování. Není

proto divu, že i u analytiky učení uvádějí mnozí autoři právě tyto dvě oblasti jako jedny z hlavních historických kořenů (např. Buckingham Shum, 2012; Cooper, 2012b, Ferguson, 2012a, 2012b; Macfadyen & Dawson, 2012).

O **webové analytice** se začíná hovořit poté, co se rozšířilo komerční využití webových stránek, resp. webové technologie obecně. Jakmile totiž začaly nejrůznější firmy postupně využívat webové stránky ke svému podnikání, ukázalo se jako užitečné (tj. výdělečné) sledovat návštěvnost stránek. Firmy proto začaly věnovat pozornost tomu, jakým způsobem se na jejich webových stránkách uživatelé pohybují a jak je využívají. Na základě těchto znalostí pak firmy mohly nechat své stránky upravit a optimalizovat, což jim následně přinášelo větší zisky. Webová analytika se tak ustanovila jako oblast zabývající se sběrem, měřením, analýzou a vyhodnocováním webových dat za účelem porozumění chování uživatele a optimalizace webových stránek (Kaushik, 2011).

V průběhu 90. let a na přelomu tisíciletí (viz Ferguson, 2012a; Macfadyen & Dawson, 2012) se pak technologie webu začala využívat i pro účely výuky, kdy se mezi vzdělávacími institucemi rozšířilo využívání systémů pro řízení výuky (LMS). Po tomto masovém rozšíření webových výukových systémů se tak i v kontextu vzdělávání začalo uvažovat o možnostech analýzy návštěvnosti online vzdělávacího prostředí s cílem jeho následné optimalizace a lepšího učení v něm. Jedním z hlavních pramenů analytiky učení je tak myšlenka aplikace webové analytiky ve specifickém kontextu online vzdělávacích systémů založených na webových technologiích.

Stejně výrazným příspěvkem do formování analytiky učení však byla oblast podnikové analytiky, resp. **business intelligence**. V případě podnikové analytiky jde o využití analytiky především v souvislosti se zvyšováním efektivity firemních procesů a podporou strategického managementu a rozhodování. Tento směr využití analytiky je dokonce starší než webová analytika. A také v kontextu vzdělávání se uvažování o analytice ve vzdělávání ubíralo nejprve tímto směrem. Již v roce 2005 Goldstein a Katz (2005) hovoří o akademické analytice jako o využití business intelligence v akademickém sektoru za účelem zlepšení organizačních procesů a zvýšení efektivity v rámci univerzity. Podobně Campbell, DeBlois a Oblinger (2007) či Fritz (2011) přibližují akademickou analytiku jako oblast zabývající se primárně administrativními a provozními záležitostmi vzdělávacích institucí. Zde může jít například o záležitosti týkající se rozpočtu a plánování, řízení lidských zdrojů, financí a fundraisingu nebo správy institucionálního výzkumu.

Lze tedy říci, že dvě výše zmíněné oblasti využití analytiky ve firemní sféře daly vzniknout dvěma různým směrům využití analytiky ve vzdělávání. Na jedné straně stojí analytika učení inspirována primárně webovou analytikou a zaměřující se na samotné procesy učení

a vyučování, na druhé straně se pak nachází akademická analytika, která vychází z podnikové analytiky a souvisí především s problematikou řízení vzdělávacích institucí.

### **2.1.3. Další oblasti formující analytiku učení a data mining ve vzdělávání**

Vedle výše uvedených disciplín či výzkumných oblastí však můžeme identifikovat ještě několik dalších oblastí výzkumu, které se významně podílely na vzniku a formování analytiky učení a data miningu ve vzdělávání. Nejdříve je ale nutno podotknout, že v případě analytiky učení lze za zřejmě nejdůležitější inspirační zdroj považovat právě data mining ve vzdělávání. Jak bylo zmíněno výše, komunita výzkumníků v rámci data miningu ve vzdělávání se ustanovila o několik let dříve, než vůbec začala být věnována pozornost oblasti označované jako analytika učení. Jakmile se pak začala ustanovovat analytika učení jako svébytná výzkumná oblast, mohla již výrazně čerpat z existující komunity výzkumníků zaměřujících se na data mining ve vzdělávání. Z toho důvodu je zároveň většina níže zmiňovaných oblastí důležitým inspiračním zdrojem nejen pro data mining ve vzdělávání, ale i pro analytiku učení.

Pokud by měl být vybrán jeden hlavní inspirační zdroj pro data mining ve vzdělávání, pak by šlo zřejmě o oblast **modelování uživatelů** (*user modeling*). Jde o oblast výzkumu v rámci multidisciplinárního oboru studujícího interakci mezi člověkem a počítačem<sup>42</sup>. Cílem výzkumníků v této oblasti je porozumět tomu, jak různí uživatelé interagují s určitou aplikací či uživatelským rozhraním. Následně je možné vytvořit model, na jehož základě může daná aplikace či rozhraní reagovat odlišnými způsoby na různé formy interakce uživatele s aplikací či rozhraním. A to například tím, že se vzhled aplikace přizpůsobí podle potřeb uživatele nebo se mu doporučí nějaký relevantní obsah apod. V kontextu data miningu ve vzdělávání se pak často hovoří o modelování studentů (viz např. Romero, Ventura, Pechenizkiy, & Baker, 2010; Peña-Ayala, 2014; Papamitsiou & Economides, 2014), kam může spadat např. modelování chování studentů, modelování jejich emočních či afektivních stavů, modelování motivace či nálady studentů apod. Dlužno také doplnit, že řada autorů (např. Ferguson, 2012a, 2012b; Chatti et al., 2012; Siemens, 2013) zmiňuje modelování uživatelů zároveň jako jeden z důležitých inspiračních zdrojů i v souvislosti s formováním analytiky učení.

Zásadní důležitost široké oblasti uživatelského modelování pro data mining ve vzdělávání i analytiku učení lze spatřovat především v tom, že určitá forma modelování uživatelů se stala jejich inherentní součástí. Řada projektů a výzkumů v oblasti analytiky a data miningu ve

---

<sup>42</sup> V angličtině se pro tento obor vžilo označení *Human-Computer Interaction* (HCI), které se do češtiny překládá jen velmi zřídka.

vzdělávání tak zahrnuje alespoň nějaký aspekt modelování uživatelů. Zároveň je vliv modelování uživatelů patrný také v tom, že vedle vlastního modelování uživatelů existuje hned několik specifitěji zaměřených výzkumných oblastí, které jsou na modelování uživatelů postaveny a které lze rovněž považovat za inspirační zdroje analytiky a data miningu ve vzdělávání.

Předně lze zmínit oblast **doporučovacích systémů** (*recommender systems*), kterou v kontextu analytiky i data miningu ve vzdělávání zmiňuje řada autorů (např. Romero & Ventura, 2013; Siemens, 2013; Peña-Ayala, 2014). Doporučovací systémy jsou samozřejmě široce používány i mimo vzdělávací prostředí<sup>43</sup>. V kontextu vzdělávání je pak cílem těchto systémů doporučit studentům takový výukový obsah (nebo úkol, odkaz apod.), který je pro ně v dané době nejvhodnější. Právě zde vstupuje do hry již zmiňovaná problematika modelování uživatelů, jelikož chceme-li doporučit studentům vhodný obsah např. na základě jejich znalostí, je nutné nejprve modelovat studenty s ohledem na jejich znalosti. Teprve na základě vytvořeného modelu jim pak lze doporučovat odpovídající obsah. Základní fungování doporučovacích systémů lze tudíž popsat tak, že nejprve shromažďují potřebné údaje o chování, znalostech či preferencích studentů, a s využitím modelování pak z těchto dat vyvozují závěry ohledně obsahu, který by byl pro konkrétního studenta vhodný či jej mohl zajímat (viz Chatti et al., 2012).

Mezi další oblasti silně stavějící na modelování uživatelů patří oblast **inteligentních tuteurských systémů** (*intelligent tutoring systems*) a oblast **adaptivních hypermediálních systémů** (*adaptive hypermedia systems*). V prvním případě jde o využívání (především) kognitivního modelování ve spojení s umělou inteligencí, přičemž cílem je tvorba takových vzdělávacích systémů, které vedou studenta v průběhu učení a jsou schopny mu poskytovat okamžitou pomoc a personalizovanou zpětnou vazbu. V druhém případě jde o systémy založené na hypertextovém a hypermediálním obsahu, které jsou schopny s využitím modelování uživatelů tento obsah adaptovat a přizpůsobit potřebám jednotlivých studentů (Brusilovsky, 2001). Rozvoj obou těchto oblastí byl zásadním impulzem především v souvislosti se vznikem data miningu ve vzdělávání (ale částečně také analytiky učení, viz např. Chatti et al., 2012; Siemens, 2013). Zároveň se tyto oblasti rozvíjejí i v současnosti, a nadále dochází k výrazným styčným plochám mezi těmito oblastmi a data miningem ve vzdělávání.

---

<sup>43</sup> Čtenář se jistě setkal např. s doporučovacím systémem (resp. jeho výstupy) na platformě YouTube, kde je jeho cílem doporučovat uživatelům relevantní videa ke zhlédnutí.

Zvláště někteří autoři z oblasti data miningu ve vzdělávání (např. Baker & Yacef, 2009; Bousbia & Belamri, 2014; Romero & Ventura, 2010, 2013) poukazují rovněž na **psychometriku** (*psychometrics*) jako jeden z významných historických kořenů data miningu ve vzdělávání. Jak uvádějí Urbánek, Denglerová a Širůček (2011), „psychometrika je nejčastěji chápána jako jakási pomocná psychologická disciplína zaměřená na tvorbu, adaptaci, úpravy a hodnocení psychodiagnostických metod“. Jak ale zároveň tito autoři doplňují, je nutné psychometriku chápat spíše jako oblast zabývající se obecně teoretickými otázkami měření v psychologii, přičemž samotná praktická aplikace určitých matematických či statistických postupů je v tomto smyslu až druhotná, jelikož vždy navazuje na obecné teoretické principy.

Vliv psychometrie na formování data miningu ve vzdělávání lze přitom vidět především v oblasti metodologie, neboť řada autorů v komunitě data miningu ve vzdělávání využívá postupů z oblasti psychometrického modelování. Jako příklad lze zmínit teorii odpovědi na položku (*item response theory – IRT*) či využití bayesovských sítí (Baker & Yacef, 2009). Romero a Ventura (2010) dokonce zmiňují, že přístupy využívané v oblasti data miningu ve vzdělávání a stavějící na psychometrickém modelování, jsou pro data mining obecně poměrně neobvyklé a nejsou univerzálně chápány jakou součástí data miningu. Je tedy patrné, že právě tyto metodologické inspirace v psychometrice jsou specifické právě pro data mining ve vzdělávání. Využívání do určité míry stejných metod je pak zřejmě odrazem toho, že se do komunity výzkumníků v oblasti data miningu ve vzdělávání zapojila řada výzkumníků původně se pohybujících v oblasti psychometrie (Baker & Yacef, 2009). Zároveň jsou zde zřejmé přesahy zvláště v kontextu měření znalostí a tvorby didaktických testů, čemuž je v psychometrice dlouhodobě věnována značná pozornost. Není tak vůbec od věci, když Baker, Martin a Rossi (2017) chápou oblast data miningu ve vzdělávání jako oblast, která do značné míry navazuje na relativně dlouhou historii problematiky měření v psychologii.

Co se týče dalších metodologických inspirací, upozorňují Chatti et al. (2012) ale také Chernobilsky et al. (2016) na výrazné styčné plochy mezi analytikou učení a **akčním výzkumem** (*action research*). Základní charakteristiky akčního výzkumu a analytiky učení (ale částečně i data miningu ve vzdělávání) jsou totiž dle těchto autorů velmi podobné. Akční výzkum v pedagogice se často zaměřuje na konkrétní školní situaci a není neobvyklé, když se na něm podílí samotní učitelé. Jeho hlavním cílem je zdokonalování pedagogické praxe a zvyšování kvality práce učitelů, což má vést k celkovému zkvalitňování poskytovaného vzdělávání. Esenciální charakteristikou je zásah do dosavadní vzdělávací praxe. V průběhu akčního výzkumu proto dochází k zavádění určitých změn. Prováděné intervence mají přitom cyklický charakter, kdy je každá z intervencí nejprve vyhodnocena a teprve poté je stanovován

další postup výzkumu. Průběh akčního výzkumu tak bývá často konceptualizován v podobě iterativního cyklu (Nezvalová, 2003). Stejně tak postup v analytice učení bývá pojímán jako opakující se cyklus zahrnující průběžné intervence a zavádění změn (viz níže). Podobně je cílem analytiky učení zlepšení a zkvalitnění edukační praxe.

Přesto můžeme mezi akčním výzkumem a analytikou učení nalézt i několik zásadních rozdílů. Zatímco na akčním výzkumu často participují především učitelé a studenti resp. žáci, výzkumné projekty založené na analytice učení často zahrnují více zúčastněných stran (např. vedení instituce, technické oddělení instituce apod.). Chatti et al. (2012) zmiňují také rozdíl v tom, čím vlastně samotný výzkumný projekt začíná. U akčního výzkumu jde obvykle o problémy či otázky, které vyplývají z vlastní pedagogické praxe. Výzkumné projekty v rámci analytiky učení se naopak formují často až na základě pozorování a analyzování již získávaných dat. V neposlední řadě se analytika učení a akční výzkum odlišují v samotných výzkumných metodách a postupech, které používají. Zatímco v akčním výzkumu je běžnější použití kvalitativních metod, analytika učení stojí téměř výhradně na metodách kvantitativních.

V neposlední řadě je třeba spolu se Siemensem (2013) zmínit jako důležitý zdroj mnoha inspirací pro analytiku učení (ale i data mining ve vzdělávání) celou oblast **e-learningu**. A to ve smyslu, který v českém kontextu dlouhodobě prosazuje především Zounek a jeho žáci, kteří chápou e-learning jako širokou oblast jak teoretického studia a empirických výzkumů, tak i reálných vzdělávacích procesů spočívajících na práci s informačními a komunikačními technologiemi (viz Zounek, 2009 či nověji Zounek et al., 2016). Právě obrovské rozšíření a reálné využívání ICT ve výuce totiž vůbec umožnilo vznik oblastí jako data mining ve vzdělávání a analytika učení. Zároveň široké spektrum realizovaných výzkumů v oblasti e-learningu výrazným způsobem přispělo ke znalostní i metodologické bázi obou těchto oblastí a ovlivnilo tak jejich další formování a směřování.

## 2.2. Základní vymezení a hlavní koncepty

Po nastínění historického kontextu v předchozí kapitole se tato část zaměřuje na přesnější vymezení oblastí označovaných jako data mining ve vzdělávání a analytika učení. Popíše proces aplikování data miningu a analytiky v kontextu vzdělávání, představím základní typy dat, která bývají v těchto oblastech analyzována a stručně charakterizují základní metody data miningu a analytiky používané v oblasti vzdělávání. Zároveň je třeba upozornit, že ačkoli jsou některé podkapitoly uvedeny jen v souvislosti s jednou z oblastí (např. typy dat či používané metody v souvislosti s data miningem ve vzdělávání), je třeba je chápat jako do značné míry platné pro obě popisované oblasti. Tzn., že například co se týče typů analyzovaných dat

a používaných metod, lze odpovídající kapitoly považovat za platné i pro analytiku učení. A to i přesto, že jsou mezi oběma oblastmi určité rozdíly, jak dokladují poslední část této kapitoly.

### **2.2.1. Vymezení a konceptualizace data miningu ve vzdělávání**

Ačkoli v rámci data miningu ve vzdělávání nenajdeme jednu všeobecně přijímanou definici této výzkumné oblasti, za jednu ze stěžejních definic lze považovat tu, kterou nabízejí Baker a Yacefová (2009), jež ve své přehledové studii vymezují oblast data miningu ve vzdělávání jako „vznikající disciplínu zabývající se rozvojem metod pro zkoumání jedinečných typů dat, která pocházejí ze vzdělávacích prostředí, a použití těchto metod pro lepší porozumění studentům a prostředím, ve kterých se učí“<sup>44</sup>. Toto vymezení data miningu ve vzdělávání je zároveň přijímáno i Mezinárodní společností pro data mining ve vzdělávání a souvisejícím časopisem, který tato společnost vydává<sup>45</sup>.

Výše uvedená definice je však poměrně široká a zároveň poněkud překvapivě vůbec nezmiňuje obecnou oblast data miningu. Naopak Romero a Ventura (2013) se k data miningu jako takovému výslovně hlásí, když říkají, že oblast data miningu ve vzdělávání může být jednoduše definována jako „aplikace data miningových technik na specifické typy dat, která pochází ze vzdělávacích prostředí“<sup>46</sup>. Přitom podobně jako Baker a Yacefová (2009) upozorňují, že cílem data miningu ve vzdělávání je hledání odpovědí na důležité pedagogické otázky. Bakhshinategh, Zaiane, ElAtia a Ipperciel (2018) rovněž odkazují k obecnému data miningu a definují data mining ve vzdělávání jednoduše jako oblast využívající techniky data miningu ve vzdělávacích prostředích. Romero a Ventura (2013) následně vymezení oblasti data miningu ve vzdělávání zpřesňují a tvrdí, že se „zabývá vývojem, výzkumem a aplikací počítačových metod pro detekci vzorců ve velkých sbírkách vzdělávacích dat, která by jinak byla analyzovatelná jen těžko či vůbec“<sup>47</sup>. Podobně Baker a Inventado (2014) upřesňují, že v případě data miningu ve vzdělávání jde především o velké objemy dat (*large-scale*

---

<sup>44</sup> Originální znění: „Educational Data Mining is an emerging discipline, concerned with developing methods for exploring the unique types of data that come from educational settings, and using those methods to better understand students, and the settings which they learn in.“ (Baker & Yacef, 2009).

<sup>45</sup> Jak již bylo zmíněno výše, jde o společnost s názvem *International Educational Data Mining Society* a časopis nazvaný *Journal of Educational Data Mining*.

<sup>46</sup> Originální znění: „In fact, EDM, can be defined as the application of data mining (DM) techniques to this specific type of dataset that come from educational environments to address important educationa questions.“ (Romero & Ventura, 2013)

<sup>47</sup> Originální znění: „Educational data mining (EDM) is concerned with developing, researching, and applying computerized methods to detect patterns in large collections of educational data that would otherwise be hard or impossible to analyze (...).“ (Romero & Ventura, 2013)

*educational data*) a o aplikaci automatických metod (tj. metod z oblasti data miningu) při jejich analýze.

Calders a Pechenizkiy (2011) kladou při vymezení data miningu ve vzdělávání důraz na poněkud odlišné prvky než výše zmiňovaní autoři. Předně považují data mining ve vzdělávání za multidisciplinární výzkumnou oblast, do které vstupují výzkumníci a specialisté z disciplín jako jsou informatika, pedagogika, psychologie, psychometrika a statistika. Dále zdůrazňují, že data mining ve vzdělávání je zároveň vědou o učení<sup>48</sup> a zároveň aplikační oblastí obecného data miningu. Vždy je však primárním cílem porozumění tomu, jak probíhá učení. V neposlední řadě pak vidí Calders a Pechenizkiy data mining ve vzdělávání jako oblast, která umožňuje daty řízené rozhodování, s jehož využitím usiluje o zlepšení současné vzdělávací praxe. Tím zároveň data mining ve vzdělávání do značné míry přibližují akčnímu výzkumu (podobně jako je tomu u analytiky učení).

Pokud bychom chtěli podat určité shrnutí různých definic data miningu ve vzdělávání a nabídnout obecné vymezení této oblasti, pak lze za hlavní charakteristické prvky data miningu ve vzdělávání považovat následující:

- Jde o aplikaci metod a technik (obecného) data miningu v kontextu vzdělávání.
- Pozornost je věnována především „velkým datům“ (*big data*), která jsou obtížně analyzovatelná běžnými statistickými metodami.
- Cílem je s využitím zmiňovaných metod a dat získávat odpovědi na pedagogické otázky týkající se učení a prostředí, ve kterých učení probíhá.
- Jde o nově se formující oblast, která čerpá teoretické a metodologické přístupy i z dalších relevantních oblastí mimo obecný data mining.

Pro bližší pochopení oblasti data miningu ve vzdělávání v následujících podkapitolách podrobněji popíšeme proces aplikace data miningu ve vzdělávání a poté představím základní typy analyzovaných dat a používaných data miningových metod.

### **2.2.1.1. Proces data miningu ve vzdělávání**

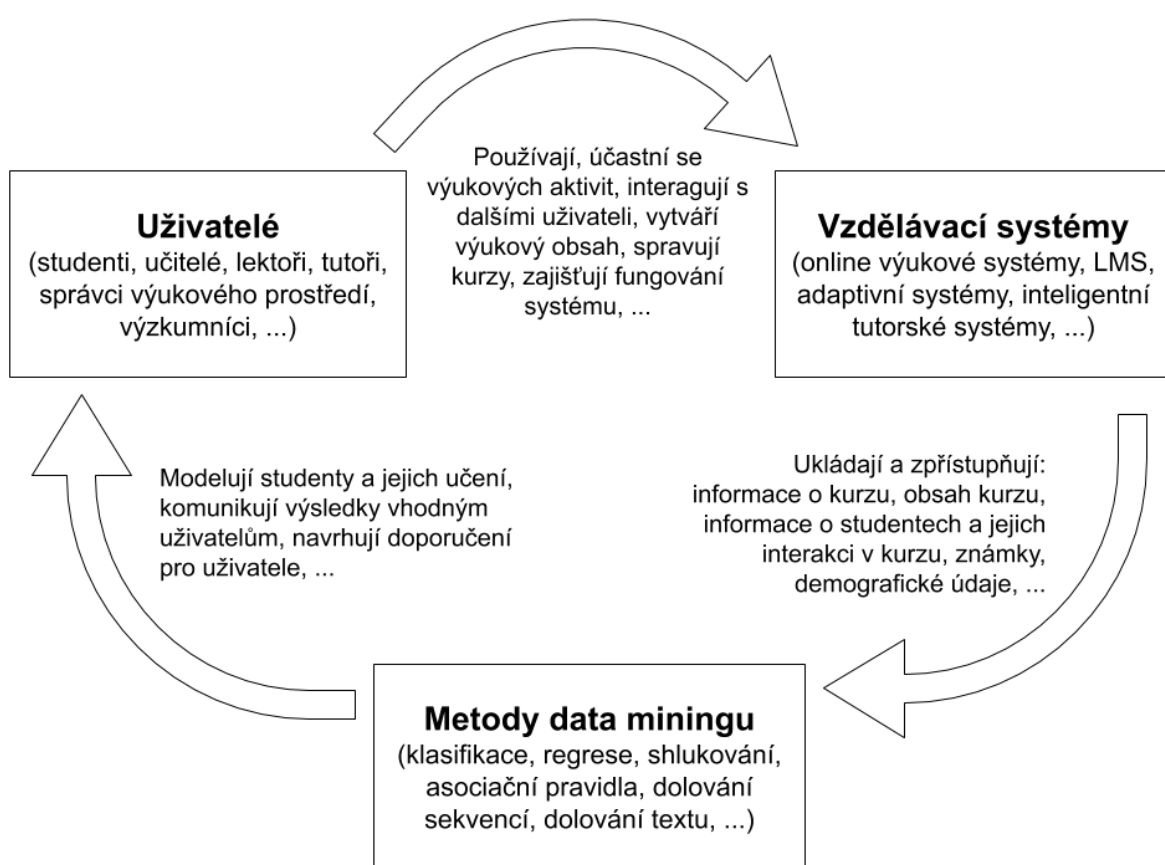
Na proces aplikace data miningu ve vzdělávání se můžeme dívat vícero způsoby. V dosavadní odborné literatuře zaměřující se na tuto oblast lze však rozlišit především dva

---

<sup>48</sup> Zde zmiňovaní autoři využívají termín „learning science“, čímž podle všeho odkazují k oblasti označované v zahraniční literatuře jako *learning sciences*. Vzhledem k zaměření práce není nutné věnovat pozornost tomu, nakolik jde v případě věd(y) o učení o zvláštní výzkumné pole a nakolik jde o jiné označení či součást běžného pedagogického výzkumu. Pro podrobnější informace lze proto pouze odkázat na stránky mezinárodní společnosti pro vědy o učení (*International Society of the Learning Sciences*) na adrese [www.isls.org](http://www.isls.org).



základní způsoby konceptualizace procesu aplikace data miningu v kontextu vzdělávání. V prvním případě vychází konceptualizace z chápání data miningu ve vzdělávání jakožto formativní evaluační techniky (viz Romero & Ventura, 2010), jejímž cílem je zlepšení učení studentů v rámci určitého vzdělávacího systému či programu. Metody a techniky data miningu zde pak slouží především k tomu, aby s jejich využitím bylo možné získat důležité informace o tom, jakým způsobem studenti systém používají. Tyto informace pak mohou být využity tvůrci daného systému či vzdělavateli v daném systému jako jeden z podkladů pro rozhodování o případných úpravách systému či změnách ve způsobech jeho využívání. Proces aplikace data miningu ve vzdělávání je pak v tomto smyslu chápán jako iterativní cyklus, který je znázorněn na následujícím obrázku (viz obrázek 7).



Obrázek 7: Konceptualizace procesu aplikace data miningu ve vzdělávání jakožto formativní evaluační techniky (podle Romero, Ventura, Pechenizkiy, & Baker, 2010).

Jak je z obrázku patrné, můžeme uvažovat o různých typech uživatelů (studenti, učitelé, administrátoři kurzů) a dalších subjektech zainteresovaných v procesu vzdělávání. Tyto zúčastněné strany jsou zároveň uživateli určitého vzdělávacího systému (příp. i více systémů současně). Tímto systémem může být např. online systém pro řízení výuky (LMS), systém

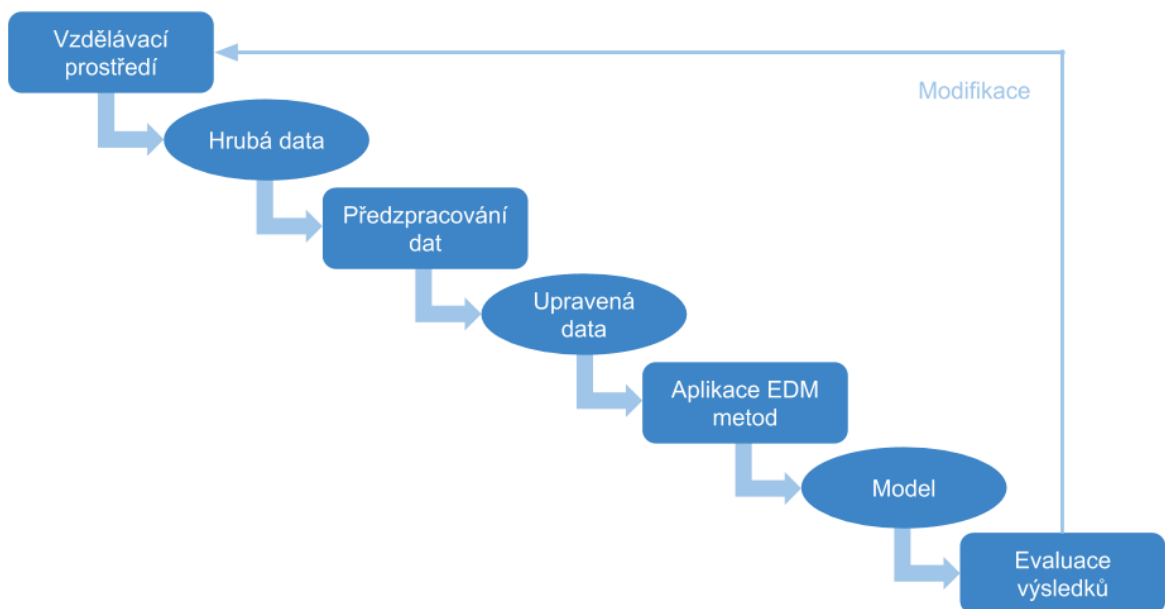
typu ITS aj.<sup>49</sup> Každá ze zúčastněných stran však využívá daný vzdělávací systém jinými způsoby. V případě LMS tak např. studenti participují v online kurzech, pracují se studijními materiály, plní výukové aktivity apod., učitelé vytváří studijní obsah kurzu a vedou kurzy, administrátoři systému zajišťují jeho provoz apod.

Různé typy vzdělávacích systémů přitom sbírají různé typy dat, které jsou analyzovatelné s využitím data miningových metod a technik. Může jít např. o data týkající se obsahu kurzů či o tom, jak s obsahem studenti interagují, data o vzájemné komunikaci studentů, o získaných známkách apod. Tato data pak mohou být ze vzdělávacích systémů extrahována a mohou na ně být aplikovány různé data miningové techniky jako shlukování, klasifikace, dolování z textu, dolování dat s využitím asociačních pravidel a další (podrobněji viz níže kapitola 2.2.1.3. *Základní metody data miningu ve vzdělávání*). Výsledky získané aplikací data miningových metod jsou následně prezentovány jeho (různým) uživatelům. Tak může být studentům například zobrazeno personalizované doporučení určitých studijních materiálů, učitelé naopak mohou být například informováni o studentech, kteří mají v kurzu nějaké problémy nebo se v kurzu chovají nějakým způsobem nestandardně apod. Tím se zároveň uzavírá jeden běh cyklu a může začít běh nový, jelikož na základě zobrazených výsledků se uživatelé opět nějakým způsobem ve vzdělávacích systémech chovají, což je opět zaznamenáváno a může být následně analyzováno.

Druhý způsob konceptualizace data miningu ve vzdělávání vychází do značné míry z obecného procesu dobývání znalostí z databází, jak je obvykle prezentován v odborné literatuře zaměřené na data mining obecně (viz např. Fayyad, Piatetsky-Shapiro, & Smyth, 1996). Jak je patrné ze znázornění procesu na obrázku níže (viz Obrázek 8: Konceptualizace procesu aplikace data miningu ve vzdělávání inspirovaná obecným procesem dobývání znalostí z databází (podle Bousbia & Belamri, 2014).obrázek 8), je zde zaměřena pozornost primárně na samotný proces práce s daty. V určitém smyslu lze tak tento způsob konceptualizace procesu data miningu chápat jako úžeji zaměřený, než způsob popisovaný výše.

---

<sup>49</sup> V širším smyslu lze pak za systém považovat tradiční výuku ve školní třídě a jakékoli další uspořádání výuky, ve kterém nejsou pro komunikaci a interakci využívány (pouze) elektronické prostředky.



Obrázek 8: Konceptualizace procesu aplikace data miningu ve vzdělávání inspirovaná obecným procesem dobývání znalostí z databází (podle Bousbia & Belamri, 2014).

Výše znázorněné fáze procesu aplikace data miningu ve vzdělávání lze podrobněji popsat následovně (srov. Bousbia & Belamri, 2014; Romero & Ventura, 2013):

1. **Vzdělávací prostředí.** V první fázi začínáme s určitým vzdělávacím prostředím, v rámci kterého mohou být sbírány určité typy dat. Opět může jít o poměrně různorodá vzdělávací prostředí od online vzdělávacích systémů, přes různé administrativní systémy až po prostředí školní třídy. V závislosti na typu prostředí jsou pak dostupné různé typy dat. Tato data jsou však v jednotlivých vzdělávacích systémech obvykle ukládána v takové podobě, že na ně nelze přímo aplikovat metody data miningu. Jde tedy o tzv. hrubá data (*crude data* či *raw data*), která musí být nejprve určitým způsobem zpracována pro jejich další využití.
2. **Předzpracování dat.** Další fází je tak tzv. předzpracování dat. Tím jsou myšleny úpravy dat, které umožní transformovat původní hrubá data do takové podoby, aby na ně mohly být aplikovány vybrané data miningové techniky. Nutno podotknout, že v kontextu vzdělávání je tato fáze často velmi náročná a zároveň zásadně důležitá. Data ve vzdělávacích systémech se obvykle vyskytují v různých úrovních granularity (viz níže), jsou ukládána v různých formátech, mají víceúrovňovou strukturu apod. Zároveň je ve vzdělávacích systémech k dispozici velké množství dat různých typů, ve kterých je třeba se nejprve zorientovat a vybrat pouze ta data, která jsou podstatná pro řešení daného problému či zodpovězení položené otázky.

Výsledkem této fáze jsou upravená či transformovaná data, která jsou nachystaná pro aplikaci data miningových metod.

3. **Aplikace data miningových metod.** V rámci aplikace konkrétních data miningových metod na připravená data, může jít o využití obecných data miningových metod, které jsou použitelné i v jiných oblastech (např. shlukování, klasifikace apod.). Často je však zapotřebí zohlednit právě kontext vzdělávání, který může mít určitá specifika a může vyžadovat využití specifických data miningových metod. Může jít např. o metody, které zohledňují hierarchickou povahu dat v kontextu vzdělávání či metody modelování longitudinálních dat apod. Zároveň je ale třeba říci, že data mining ve vzdělávání je i dnes poměrně mladou a rozvíjející se výzkumnou oblastí, a tudíž právě porozumění specifickým vlastnostem vzdělávacího kontextu a vývoj odpovídajících přizpůsobených či zcela nových data miningových technik je stále jedním z primárních cílů výzkumníků v této oblasti. Výsledkem aplikace data miningových technik je obvykle nějaký model. Může jít např. o model, podle kterého jsou studentům doporučovány další studijní materiály k rozšíření znalostí či model, který predikuje úspěšnost studentů v kurzu apod.
4. **Evaluace výsledků.** Závěrečnou fází data miningového procesu je pak evaluace či interpretace vytvořených modelů. Tato fáze je zcela zásadní pro následné uplatnění modelů a získaných poznatků ve vzdělávací praxi (tj. pro účely rozhodování, pro účely modifikace systému atd.). Uživatelé výstupů modelování, ať už to jsou přímo studenti a učitelé či jiné zainteresované subjekty, totiž musí být schopni výstupům porozumět, aby mohli zvolit odpovídající reakci<sup>50</sup>. Aplikací vytvořených modelů do vzdělávacího prostředí zároveň dochází k úpravě či modifikaci tohoto prostředí, čímž se uzavírá celý cyklus a může tak začít jeho nový běh.

---

<sup>50</sup> Doplňme, že interpretace data miningových modelů je do značné míry obecným problémem. Některé data miningové techniky totiž sice vedou k dobrým výsledkům, co se týče úspěšnosti predikce, ale na druhou stranu produkují modely, které jsou jen obtížně interpretovatelné (někdy se používá označení *black-box models*; typickým příkladem takové techniky jsou neuronové sítě). V některých případech proto může být preferován takový model, který má sice horší predikční schopnosti, ale je velmi snadno interpretovatelný, a tudíž srozumitelný (tzv. *white-box model*; příkladem může být modelování s využitím techniky rozhodovacích stromů). Velmi užitečnou publikací je v tomto kontextu volně dostupná kniha Molnara (2019).

Jak je z výše uvedeného patrné, v pozadí obou konceptualizací procesu data miningu ve vzdělávání stojí obecný iterativní proces výzkumné práce založený na formulování hypotéz, jejich testování resp. ověřování a následném vyhodnocení a formulování hypotéz nových (Romero & Ventura, 2013). Zároveň lze již nyní zmínit, že obdobným způsobem je konceptualizován i proces analytiky učení (viz kap. 2.2.2.2.).

### **2.2.1.2. Typy dat využívané v rámci data miningu ve vzdělávání**

Jak bylo již naznačeno výše, při aplikaci data miningu ve vzdělávání (ale i analytiky učení)<sup>51</sup> se lze setkat s různými typy dat. To, o jaká data se právě jedná, přitom zcela zásadně ovlivňuje, jaké data miningové postupy a techniky lze použít. Podobně zároveň typ dostupných dat ovlivňuje to, jaké pedagogické otázky lze s využitím metod data miningu vůbec zodpovědět. K vytvoření typologie dat je však možné využít poměrně různorodá kritéria. Níže proto není podána jediná typologie dat, nýbrž je představeno několik odlišných způsobů, jakým jsou obvykle rozlišovány různé typy dat v kontextu data miningu ve vzdělávání.

Do jisté míry výchozím kritériem pro rozlišení různých typů dat může být **obsah, který data reprezentují**. Zde lze využít typologii Sclatera (2017), kterou sice představuje primárně ve spojení s analytikou učení, ovšem je dobře využitelná i v souvislosti s data miningem ve vzdělávání. Sclater rozlišuje čtyři základní kategorie dat. První kategorií jsou základní *demografické údaje*, které škola o svých studentech uchovává. Sem mohou spadat údaje jako datum narození, pohlaví, bydliště či místo narození, rodinný stav apod. Druhou kategorií jsou tzv. *akademická data*, která zahrnují údaje týkající studia jednotlivých studentů. Jde tak např. o volbu předmětů, známky resp. hodnocení z absolvovaných předmětů, odevzdané úkoly či závěrečné práce apod. Spadají údaje o „cestě“ studenta studiem (tj. např. volba předmětů) a o jeho pokrocích (tj. absolvování předmětu), ale také data reprezentující obsah generovaný studenty v průběhu plnění studia či dílčích kurzů (tj. seminární práce, eseje apod.). Třetí kategorií jsou *data o učební aktivitě studentů*. Zde má Sclater na mysli primárně data z různých typů online výukových systémů (např. LMS), která jsou obvykle generována automaticky v podobě tzv. logů. Poslední typ dat lze pak na základě Sclatera nazvat *daty o vzdělávacím kontextu*. Sem spadají všechny údaje, které mohou poskytovat potřebný kontext pro výše uvedené typy dat. Může jít např. o detailní informace o zamýšleném kurikulu či studijním plánu, které by poskytovaly nezbytný kontext pro analýzy

---

<sup>51</sup> Na tomto místě je vhodné podotknout, že co se týče typů využívaných resp. analyzovaných dat, je možné obsah této části považovat za platný jak pro data mining ve vzdělávání tak i pro analytiku učení. V obecném pohledu lze totiž říci, že se obě tyto výzkumné oblasti zaměřují na stejné typy dat. A to i přes to, že při bližším pohledu mohou být jednotlivé typy dat v daných oblastech akcentovány v odlišné míře.

zaměřující se na volbu jednotlivých předmětů a studijních cest studentů. Jiným příkladem mohou být informace doplňující kontext k jednotlivým kurzům, např. trvání kurzu, způsob ukončení kurzu, studijní materiály a aktivity v kurzu včetně plánovaného termínu jejich splnění apod. Taková „kontextová“ data mohou být relevantní zvláště v případech, kdy je věnována pozornost predikci úspěšnosti studentů v jednotlivých kurzech.

Za další ze základních kritérií pro rozlišení různých typů dat lze považovat **vzdělávací prostředí** či systém, ze kterého data pocházejí (srov. např. Bousbia & Belamri, 2014). Na jedné straně zde máme různé typy počítačem podporovaného vzdělávání, kde může jít o data pocházející ze systémů pro řízení výuky (LMS), ale i jiných typů virtuálních vzdělávacích prostředích (VLE). Byly např. zmíněny inteligentní tutorské systémy (ITS) a adaptivní hypermediální systémy (AHS). Existují ovšem i vzdělávací systémy na podporu spolupráce a počítačem podporovaného kolaborativního učení (CSCL), či tzv. osobní vzdělávací prostředí (PLE) a e-portfolia, jejichž data rovněž mohou být vytěžována. Data mohou dále pocházet i z výukových her či tzv. vážných her (*serious games*), případně může jít o data z různých online testovacích systémů, hlasovacích systémů (tzv. *student response systems*) a jiných elektronických výukových platforem. Na druhé straně ale může jít i o různé typy dat pocházejících z tradičního (myšleno „off-line“) vzdělávacího prostředí. V těchto případech mohou být data dostupná v různých vzdělávacích informačních systémech (EIS) či studentských informačních systémech (SIS). Také může být nutné tato data nejprve převést do elektronické podoby (jsou-li např. zaznamenávána pouze v papírové podobě) či dokonce nejprve navrhnout, jak by vůbec mohla být sbírána (v případě, že jde o data, která se doposud nesbírají).

Jiným rozlišovacím kritériem může být **způsob sběru dat** (Bousbia & Belamri, 2014). Velmi často bývají data sbírána automatizovaně v digitální podobě, jak je tomu u zmiňovaných online vzdělávacích systémů. Zde samozřejmě záleží na daném systému, jaká konkrétní data automaticky zaznamenává. Obvykle jde však o nějakou podobu tzv. logů, které zaznamenávají určité typy událostí, které v systému nastávají. K dispozici jsou i data v digitální podobě, která nejsou generována automaticky. Zde může jít např. o již zmiňované seminární práce odevzdávané studentem v digitální podobě, příspěvky studentů v online diskuzních fórech, ale také např. videozáznamy výuky apod. Data však mohou být sbírána i manuálně, případně mohou být kombinovány různé typy sběru dat. Typickým příkladem je situace, kdy výzkumník provádí pozorování dění ve školní třídě zatímco studenti pracují s určitým vzdělávacím softwarem, přičemž tato manuálně zaznamenávaná data z pozorování jsou následně spojena s automaticky sbíranými daty ze vzdělávacího softwaru.

Sbíraná data obvykle obsahují osobní či citlivé údaje, proto se lze na sběr dat dívat i z hlediska toho, nakolik dochází k **získávání a zpracovávání dat osobní či citlivé povahy**. Sclater (2017) v tomto kontextu zmiňuje tzv. poskytované údaje (*provided data*), tzn. data, která individuální subjekt (obvykle student) vědomě poskytuje. Příkladem takto vědomě poskytnutých dat mohou být údaje získávané s využitím online dotazníků či formulářů, které student dobrovolně vyplní a odešle. Jiným příkladem jsou data pramenící z pozorování v širokém slova smyslu (*observed data*). Zde má Sclater na mysli jakákoli automaticky zaznamenávaná data, která se nějakým způsobem týkají činnosti sledovaných subjektů. Spadají sem tedy již zmiňované logy a další typy automaticky zaznamenávaných dat v rámci online výukových systémů. Rovněž zde ale můžeme hovořit např. o různých videozáznamech výuky či o záznamech z nejrůznějších senzorů použitých v rámci výukových experimentů apod. Za další typ dat lze pak považovat derivovaná data (*derived data*), která nejsou sbírána přímo, nýbrž jsou generována na základě jiných sbíraných dat. Zde jsou typickým příkladem různé metriky vypočítávané ze sbíraných dat (např. počet zobrazených studijních materiálů za jednu návštěvu online kurzu, průměrný počet slov na jeden online diskuzní příspěvek apod.). Posledním typem dat jsou tzv. vyvozovaná data (*inferred data*), která jsou do jisté míry podobná derivovaným datům. Opět jde o data, která nejsou sbírána přímo, nýbrž jsou nějakým způsobem odvozena od sbíraných dat. Oproti derivovaným datům však nejde o jednoduché metriky, ale o data pramenící z aplikace analytických a data miningových metod na sbíraná data. Příkladem tak mohou být data, která jsou výsledkem nějakého prediktivního systému a která uvádějí pravděpodobnost, s jakou daný student úspěšně ukončí určitý kurz. Jiným příkladem vyvozených dat může být aplikace shlukovacího algoritmu a zařazení studenta do určité skupiny či kategorie na základě jeho studijních strategií při plnění online kurzu.

Hovořit lze dále i o **dostupnosti dat** (Bousbia & Belamri, 2014; Sclater, 2017). Častým případem v kontextu data miningu ve vzdělávání a analytiku učení je situace, kdy jsou využita v rámci již instituce existující a dostupná data, která však zatím pro tyto účely nebyla využívána nebo nebyla doposud dostatečně vytěžena. Typicky tak jde o data z různých vzdělávacích a výukových online systémů, která byla v průběhu let automaticky zaznamenávána v databázích daných systémů. Jiným příkladem využití již dostupných dat mohou být data, která jsou volně k dispozici. Zde může jít např. o data dostupná v některém z široké škály obecných datových repositářů či o konkrétní datové sady zveřejněné obvykle

pro nějaké specifické účely či v souvislosti s konkrétním realizovaným výzkumem<sup>52</sup>. Nutno však zmínit, že existují i pokusy o aplikaci data miningových metod na volně dostupná data z velkých mezinárodních výzkumů (*international large scale assessments – ILSA*) jako jsou PISA, TIMSS, PIRLS či ICILS, která jsou s využitím „klasických“ statistických metod v rámci pedagogického výzkumu využívána poměrně běžně (viz např. Juhaňák et al., 2018, 2019). Čím dál tím častěji se v kontextu data miningu ve vzdělávání a analytiky učení objevují také typy dat, která jsou generována v průběhu výzkumných experimentů za využití specifických měřicích přístrojů<sup>53</sup>. Taková data jsou samozřejmě primárně nedostupná a mohou být k dispozici teprve po realizaci daného experimentu.

Důležitým kritériem pro rozlišování různých typů dat ve vzdělávání je rovněž úroveň či podrobnost popisu, tzv. **granularita dat** (Romero & Ventura, 2013). Jak naznačuje obrázek níže (viz obrázek 9), data využívaná v rámci data miningu ve vzdělávání se mohou týkat různé úrovně obecnosti, resp. mohou být různě detailní. Můžeme tak mít k dispozici data týkající se jednotlivých kurzů (např. počet studentů v kurzu, zaměření kurzu, požadované ukončení kurzu aj.), ale také data na úrovni studentů v rámci kurzu (např. získané známky v kurzu). Zároveň lze ale věnovat pozornost ještě nižším úrovním a sledovat např. jen konkrétní výukovou aktivitu v rámci kurzu či konkrétní akce studentů v rámci dané aktivity. Anebo se lze naopak zaměřit na obecnější úroveň a pracovat s daty na úrovni studijních programů či celých vzdělávacích institucí. Data v různých online vzdělávacích systémech (ale i v rámci jednoho systému) se přitom vyskytují v různých úrovních granularity, proto je obvykle nejprve nutné převést data na požadovanou úroveň granularity na základě položené otázky či záměrů výzkumu. Případně je možné provádět analýzy zohledňující více úrovní a hierarchický charakter dat (např. úroveň studentů a úroveň kurzů, ve kterých jsou zapsáni). Zmiňovaný obrázek zároveň naznačuje vztah mezi granularitou a množstvím dat. Pohybujeme-li se na

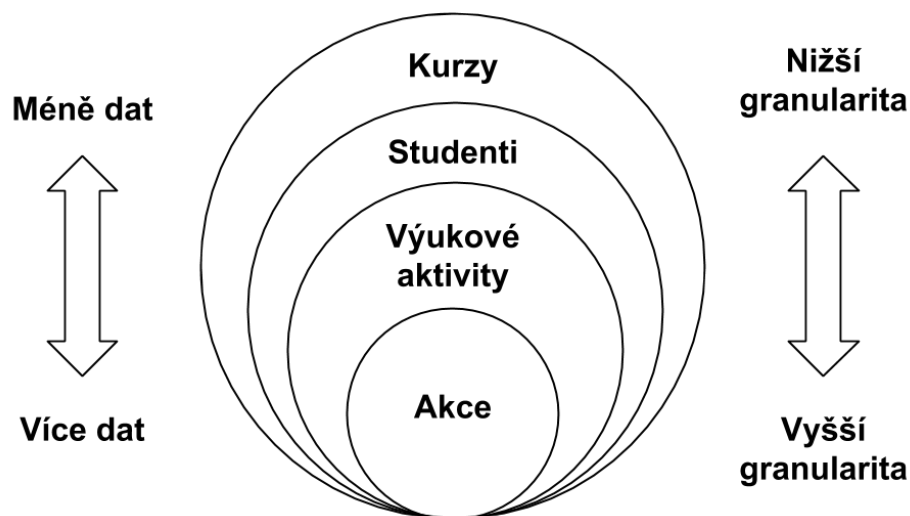
---

<sup>52</sup> Příkladem datového repozitáře může být např. repozitář *DataShop @CMU* ([pslclatashop.web.cmu.edu/](https://pslclatashop.web.cmu.edu/)). Jako příklady specificky zaměřených dat lze uvést např. *LAK Dataset* ([solaresearch.org/initiatives/dataset/](https://solaresearch.org/initiatives/dataset/)), který obsahuje metadata a strukturované plné texty klíčových výzkumných publikací v oboru analytiky učení a data miningu ve vzdělávání. Dále lze zmínit data publikovaná českým týmem, který se věnuje data miningu ve vzdělávání na Open university – viz *Open University Learning Analytics dataset* ([www.nature.com/articles/sdata2017171](https://www.nature.com/articles/sdata2017171)). Tato data pochází z online vzdělávacího systému využívaného na Open university. V neposlední řadě lze zmínit i data zveřejněná na stránkách výzkumné skupiny *Adaptive Learning*, která působí na Fakultě informatiky Masarykovy univerzity, a která se věnuje především problematice adaptivních vzdělávacích systémů, ze kterých pak pochází publikovaná data (viz [www.fi.muni.cz/adaptivelearning/?a=data](https://www.fi.muni.cz/adaptivelearning/?a=data)).

<sup>53</sup> Příkladem mohou být relativně často využívaná zařízení pro snímání očních pohybů (tzv. eye tracking). Pro širší přehled specifických měřicích přístrojů, které jsou či mohou být v tomto kontextu využívány, se lze obrátit na webové stránky laboratoře HUME Lab ([humelab.cz/services/equipment](https://humelab.cz/services/equipment)).



vysoké úrovni detailu (tj. vysoká granularita), pracujeme obvykle s velkými objemy dat, kdežto na obecnějších úrovních (nižší granularita) je množství dat nižší<sup>54</sup>.



Obrázek 9: Různé úrovně granularity a množství dat (podle Romero & Ventura, 2013).

V neposlední řadě lze pak rozlišovat různé typy dat na základě **struktury dat** (Bousbia & Belamri, 2014) resp. toho, v jaké podobě jsou údaje ukládány a uchovávány či do jaké podoby musí být údaje před aplikací data miningových metod transformovány. Za do značné míry výchozí strukturu je možné považovat tabulku, kdy jednotlivé řádky tvoří vybrané případy (studenti v kurzu, různé kurzy apod.) a sloupce tvoří sledované proměnné (známky získané v kurzu, množství studentů v kurzu apod.). S takovou strukturou dat se lze setkat i při využití tradičních metod pedagogického výzkumu (např. při dotazníkovém šetření). Obvykle se přitom v této souvislosti hovoří o tzv. atribučních datech. V rámci data miningu ve vzdělávání se však výzkumníci relativně často setkávají i s jinak strukturovanými daty. Např. při práci s daty kvalitativního (tj. textového) charakteru může být potřeba nejprve vytvořit odpovídající textový korpus (např. korpus odevzdaných úkolů či odpovědí v diskuzním fóru), než je možné data analyzovat. Data mohou zachycovat určité vztahy či sociální interakci (např. data z online diskuzních fór), a tudíž mohou být strukturována v podobě tzv. matice sousednosti či v podobě seznamu uzlů a seznamu hran. V tomto kontextu se hovoří o tzv.

<sup>54</sup> Pro lepší představu: Budeme-li se např. pohybovat na úrovni jednoho kurzu a studentů v něm, pak se u běžného univerzitního kurzu můžeme pohybovat v řádu desítek až stovek studentů. Naopak při zaměření pozornosti na úroveň konkrétních aktivit studentů v online kurzu se u běžného univerzitního kurzu dostáváme k desetitisícům až statisícům záznamů (v závislosti na počtu studentů a na množství studijních materiálů a výukových aktivit v online kurzu).

relačních datech). Jiným příkladem mohou být již zmiňované logy, u nichž lze hovořit o datech zachycujících nějaký proces resp. řadu událostí v čase. Tato data mají vlastní specifickou strukturu, kdy jednotlivé řádky v tabulce tvoří události, přičemž každá událost musí obsahovat minimálně informaci o případu, kterého se týká, o aktivitě, která je provedena, a o času, kdy událost nastala. Mimo uvedené příklady lze pak samozřejmě v realizovaných výzkumech narazit i na další typy dat se specifickou strukturou.

### **2.2.1.3. Základní metody data miningu ve vzdělávání**

Podat pokud možno systematický a zároveň dostatečně podrobný přehled metod používaných v oblasti data miningu ve vzdělávání je poměrně komplikovaný úkol. Jednak proto, že se výčty používaných metod mezi jednotlivými autory více či méně liší, ale i proto, že různí autoři seskupují metody do obecnějších kategorií odlišným způsobem. Zatímco například Baker a Inventado (2014) nabízejí čtyři základní kategorie data miningových metod ve vzdělávání, Bakhshinategh, Zaiane, ElAtia a Ipperciel (2018) nabízí výčet devíti základních metod, které neseskupují do žádných souvisejících kategorií. Níže proto představuji vlastní kategorizaci a výčet základních data miningových metod v oblasti vzdělávání. Vycházím přitom z kategorizace Bakera a Inventada (2014), kterou však upravuji a doplňuji s ohledem na další důležité zdroje v této oblasti (především Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Romero & Ventura, 2010, 2013) jakož i s ohledem na zdroje týkající se data miningu obecně (především Fayyad, Piatetsky-Shapiro, & Smyth, 1996; Gorunescu, 2011; Witten, Frank, & Hall, 2011).

#### **2.2.1.3.1. Prediktivní metody**

První skupinu metod lze označit jako *prediktivní metody*. Cílem predikce a prediktivních metod je vytvoření modelu, který je schopen odvodit či odhadnout jeden konkrétní atribut či aspekt dat (tj. predikovanou, výstupní či závisle proměnnou) na základě určité kombinace dalších aspektů dat – tj. prediktorů, resp. vysvětlujících či nezávisle proměnných (Baker & Inventado, 2014; Romero & Ventura, 2013). Prediktivní metody vyžadují, abychom předem měli určitou množinu dat, kde známe správnou hodnotu predikované proměnné. Pokud bychom využili terminologie ze související oblasti strojového učení (*machine learning*), pak lze kategorii prediktivních metod vesměs ztotožnit s tím, co se v rámci strojového učení označuje jako metody učení s učitelem (*supervised learning*). Ty se od metod učení bez učitele (*unsupervised learning*) liší právě tím, že máme k dispozici tzv. trénovací data s předem známou hodnotou predikované proměnné. Na těchto trénovacích datech se pak použitý algoritmus může „naučit“ správnou souvislost mezi prediktory a predikovanou proměnnou. Tuto naučenou „znalost“ (v podobě určitého modelu) lze pak použít na nových

datech, kde již hodnotu predikované proměnné neznáme. Obecně patří prediktivní metody mezi jedny z nejpoužívanějších. V kontextu data miningu ve vzdělávání se pak používají např. k predikci úspěšnosti studentů, k detekci různých forem chování studentů v online prostředí, k predikci úrovně znalostí studentů či k odhadování afektivních stavů studentů při plnění určitých studijních úkolů. Mezi dva základní typy metod v této kategorii pak patří metody klasifikace a regrese.

V případě **regrese** (*regression*) má predikovaná proměnná obvykle podobu číselné resp. spojité proměnné. Mezi prediktory pak mohou být jak číselné, tak i kategorické proměnné. Cílem regrese je tak na základě dostupných prediktorů odhadnout konkrétní hodnotu (číslo) výstupní proměnné. Mezi nejčastěji používané metody zde patří klasická lineární regresní analýza, pro účely predikce spojité proměnné lze však použít například i regresní stromy (*regression trees*), podpůrné vektory (*support vector machines*) či umělé neuronové sítě (*neural networks*). V kontextu data miningu ve vzdělávání je však použití těchto „pokročilejších“ metod výrazně méně časté než v jiných oblastech využívajících obecné data miningové metody. Dle Bakera a Inventada (2014) je hlavním důvodem to, že v oblasti vzdělávání hraje obvykle důležitou roli velké množství faktorů (tj. vysvětlujících proměnných) a zároveň data ze vzdělávacího kontextu často obsahují velké množství šumu (tj. chybějících dat, nepravidelností, chyb v datech apod.). V souvislosti s regresní analýzou je třeba upozornit, že ačkoli např. klasická lineární regresní analýza je běžně využívána i v kontextu statistického testování hypotéz standardně aplikovaného i v jiných oblastech výzkumu, způsob využití regresní analýzy v data miningu je mírně odlišný (např. co se týče validace modelu).

V případě **klasifikace** (*classification*) má naopak predikovaná proměnná kategorický charakter a cílem klasifikace je tak správné zařazení případu do jedné ze dvou či více možných kategorií. Mezi nejčastěji používané metody klasifikace v oblasti data miningu ve vzdělávání přitom patří logistická regrese (*logistic regression*), rozhodovací stromy (*decision trees*) a náhodný les (*random forest*). Pro účely klasifikace lze však využít i řadu jiných technik resp. klasifikačních algoritmů, jako jsou například již zmíněné podpůrné vektory a umělé neuronové sítě, ale také algoritmus k-nejbližších sousedů (*k-nearest neighbor algorithm*), naivní Bayesův klasifikátor (*naive Bayes*) či diskriminační analýza (*discriminant analysis*). Jako specifický typ metody klasifikace v oblasti vzdělávání uvádějí Baker a Inventado (2014) odhad latentních znalostí (*latent knowledge estimation*), což je metoda využívaná především v kontextu inteligentních tutorských systémů a doporučovacích systémů. Dodejme, že podle Peña-Ayaly (2014b) patří metody klasifikace v kontextu data miningu ve vzdělávání mezi zdaleka nejčastěji používané (cca 42 % ze všech analyzovaných studií).

### 2.2.1.3.2. Shlukování

Za druhou skupinu metod lze považovat tzv. shlukování či klastrování (*clustering, cluster analysis*). Základním cílem shlukování je seskupení jednotlivých případů do určitého počtu skupin (shluků) na základě jejich podobnosti. Co znamená ona „podobnost“ je pak samozřejmě různé dle analyzovaných dat a použitých shlukovacích algoritmů. Obecně lze ale podobnost chápat tak, že případy v rámci určitého shluku mají napříč jednotlivými proměnnými „blízké“ hodnoty, a naopak případy z různých shluků mají hodnoty v jednotlivých proměnných spíše odlišné (Dutt, Ismail, & Herawan, 2017). Shlukování lze přitom považovat za jednu ze základních metod učení bez učitele (*unsupervised learning*), tzn. takovou metodu, kdy se pracuje s daty, u kterých není předem známo jejich zařazení do odpovídajících kategorií (oproti klasifikaci) a nelze tedy použít trénovací data, na kterých by se algoritmus mohl „naučit“ správné zařazení případu do odpovídající kategorie.

Lze přitom souhlasit s Hebákem et al. (2013), že pojem shlukování či shluková analýza ve skutečnosti zahrnuje větší množství poměrně různorodých specifických metod a přístupů. Obecně lze metody shlukování rozdělit na hierarchické a nehierarchické. **Hierarchické metody shlukování** spočívají v tom, že je vytvářena hierarchická posloupnost postupného spojování resp. rozdělování jednotlivých případů v datech, kterou lze znázornit pomocí tzv. dendrogramu (tj. diagramu znázorňujícího onou stromovou či hierarchickou strukturu). Jednotlivé techniky hierarchického shlukování lze pak dále rozdělit na aglomerativní a divizivní. Aglomerativní algoritmy hierarchického shlukování postupují od jednotlivých případů, které postupně spojují do stále menšího počtu shluků tak, že nakonec vznikne jediný shluk tvořený všemi případy. Samotné spojování do shluků se pak provádí na základě vypočtené vzdálenosti resp. blízkosti jednotlivých případů a shluků. Divizivní algoritmy pak postupují opačně, tzn. místo spojování jednotlivých případů a následně shluků fungují tak, že jeden výchozí shluk (tj. kompletní data) postupně rozděluje na menší a menší shluky, dokud se nedopracují ke stavu, kdy každý z případů v datech tvoří svůj vlastní shluk. Za častěji využívané metody lze však považovat spíše metody aglomerativního hierarchického shlukování.

Druhým základním typem shlukovacích metod jsou **metody nehierarchického shlukování**. Jak napovídá samotné označení těchto metod, základním rozdílem oproti předchozí kategorii je to, že nepracují s hierarchickou posloupností spojování či rozdělování shluků. V rámci nehierarchických metod lze dále rozlišovat různé dílčí typy shlukovacích technik. Za jedno ze základních rozdělení můžeme považovat to, zda jde o disjunktivní či kategorické shlukování, kdy může být každý případ zařazen vždy jen do jednoho shluku, anebo jde o tzv. fuzzy či probabilistické shlukování, kdy je pro každý případ vypočtena míra

jeho příslušnosti do každého z existujících shluků (srov. Witten, Frank, & Hall, 2011). Za nejčastěji využívané metody nehierarchického shlukování lze považovat algoritmy k-shlukování a zvláště metodu k-průměrů (*k-means clustering*). Oproti hierarchickým metodám je u k-shlukování předem stanoven počet shluků, do kterých se mají data rozdělit. Samotný algoritmus pak funguje iterativně, kdy se opakovaně vypočítává tzv. centroid<sup>55</sup> jednotlivých shluků a následně se upravuje zařazení jednotlivých případů do shluků na základě jejich nejbližšího centroidu. Metoda k-průměrů patří v oblasti data miningu ve vzdělávání mezi celkově nejčastěji používané metody shlukování (viz Peña-Ayala, 2014b). Jak ale upozorňuje například Hebák et al. (2013), problémem k-shlukování je to, že dosahuje pouze lokálně optimálního řešení, které je navíc závislé na výchozí pozici centroidů resp. na pořadí případů v datech.

### 2.2.1.3.3. Metody redukce dimenzí

Třetí skupinou metod jsou *metody redukce dimenzí* či *metody redukce dimenzionality*. Tyto metody lze v určitém pohledu považovat za podobné metodám shlukování. Např. Baker a Inventado (2014) dokonce obě tyto skupiny metod zahrnují pod jednu společnou kategorii metod zabývajících se odhalováním struktury (*structure discovery*) v analyzovaných datech. Přesto považují za vhodnější rozdělit obě skupiny metod do dvou různých kategorií, jelikož je mezi nimi jeden zásadní rozdíl. Ten lze v principu vysvětlit následovně. Zatímco v případě shlukování nám jde o jednotlivé případy a jejich seskupení do skupin dle podobnosti, v případě redukce dimenzionality se zaměřujeme na proměnné a možnosti redukce jejich počtu (ať již pomocí sloučení několika proměnných do jedné, anebo výběrem jen těch nejpřínosnějších proměnných). Metody redukce dimenzí se hojně používají i mimo oblast data miningu či strojového učení, ačkoli se obvykle v různých oblastech poněkud liší používaná terminologie, a zároveň jsou tyto metody používané pro mírně odlišné účely.

V kontextu psychometrie, ale i obecně pedagogického výzkumu využívajícího dotazníkovou šetření, je relativně běžně využívanou metodou spadající do oblasti redukce dimenzionality tzv. **faktorová analýza** (*factor analysis*). Cílem faktorové analýzy je redukce většího množství naměřených proměnných na menší množství latentních (přímo neměřených) proměnných označovaných jako faktory. V řadě disciplín v rámci sociálních věd se totiž pracuje s poměrně komplexními konstrukty, které lze jen obtížně (pokud vůbec) měřit přímo. Obvykle se tak pomocí určitého množství jednodušších přímo měřených položek zjišťuje (resp. odhaduje) hodnota nějakého složitějšího přímo neměřitelného konstruktu. Tím může být např. určitá schopnost, motivace, postoj apod. Faktorová analýza pak v tomto

---

<sup>55</sup> Pro jednodušší pochopení si jej lze představit jako střed či těžiště daného shluku.

kontextu obvykle slouží k ověření toho, zda použitý měřicí nástroj skutečně měří ty konstrukty, které by měl dle předpokladu měřit. Obecně lze přitom rozlišit konfirmační faktorovou analýzu (*confirmatory factor analysis – CFA*), která předem předpokládá určitou strukturu faktorů a jednotlivých položek, a explorační faktorovou analýzu (*exploratory factor analysis – EFA*), u které není předem dán počet faktorů a jejich vztah k jednotlivým položkám.

V kontextu data miningu ve vzdělávání je častěji používanou metodou **analýza hlavních komponent** (*principal component analysis*), která je však svým charakterem velmi podobná explorační faktorové analýze. Stejně jako v případě faktorové analýzy je cílem analýzy hlavních komponent redukce výchozího počtu proměnných na menší počet „umělých“ či skrytých proměnných, které by však obsahovaly co možná největší míru informace obsaženou původní sadě proměnných. Určitý rozdíl mezi oběma metodami je pak jednak v konkrétním způsobu výpočtu<sup>56</sup>, jednak částečně také v cílech obou metod a v interpretaci jednotlivých komponent resp. faktorů. V případě metody hlavních komponent je obvykle hlavním cílem redukce původně velkého množství proměnných pro účely zjednodušení následných analýz. Primárním požadavkem je tak to, aby nové proměnné (komponenty) co nejvíce vysvětlovaly variabilitu původních proměnných, přičemž ne vždy je nutné, aby jednotlivé komponenty zároveň měly nějakou věcnou interpretaci. Naopak v rámci faktorové analýzy je věcná interpretace jednotlivých faktorů obvykle zcela zásadní, jelikož jednotlivé faktory mají odpovídat teoretickým konstruktům, kterým je v daném výzkumu věnována pozornost. Podobně je při využívání faktorové analýzy obvykle požadováno, aby vztahy mezi jednotlivými faktory (jakož i původními položkami) odpovídaly výchozím teoretickým předpokladům.

Mezi další metody redukce dimenzí, které jsou používané v oblasti data miningu ve vzdělávání, lze zařadit například lineární diskriminační analýzu (*linear discriminant analysis*) či metodu označovanou jako non-negativní faktorizace matic (*non-negative matrix factorization*), viz Romero a Ventura (2013).

#### **2.2.1.3.4. Dolování vztahů**

Další skupinu tvoří metody zaměřující se na zkoumání vztahů mezi jednotlivými proměnnými. Baker a Inventado (2014) pro označení těchto metod používají zastřešující termín dolování vztahů (*relationship mining*). Základním cílem dolování vztahů je nalezení důležitých souvislostí mezi proměnnými v datech. A to obvykle v situacích, kdy data obsahují

---

<sup>56</sup> V případě analýzy hlavních komponent se vychází z kovariační matice původních proměnných, zatímco u faktorové analýzy se pracuje spíše s korelační maticí (viz Hebák et al., 2013).

velmi velké množství proměnných. Za jednu z nejjednodušších technik lze v této oblasti považovat klasickou korelační analýzu běžně používanou i v tradičně orientovaném pedagogickém výzkumu. Pro tu se v kontextu data miningu někdy používá označení **dolování korelací** (*correlation mining*). Mimo jednoduché hledání významných korelací se však lze v oblasti dolování vztahů setkat s řadou dalších metod. Níže zmiňuji tři vybrané příklady, které patří v data miningu ve vzdělávání k častěji používaným.

Asi nejčastěji využívanou metodou dolování vztahů jsou tzv. **asociační pravidla** resp. dolování asociačních pravidel (*association rule mining*). Cílem této metody je nalézt v datech sadu často se vyskytujících pravidel v podobě jestliže-pak (*if-then*). To lze přiblížit tak, že se automaticky hledá spoluvýskyt určitých hodnot v určitých proměnných napříč jednotlivými případy. Pokud bychom chtěli dát příklad z kontextu využívání LMS, pak si lze takové asociační pravidlo představit např. v následující podobě:

- *POKUD student otevřel požadovaný studijní materiál A ZÁROVEŇ se studijním materiálem intenzivně pracoval PAK student úspěšně dokončil průběžný test.*

Takové pravidlo přitom neukazuje automaticky na kauzální vztah, ale pouze na to, že v datech existuje mnoho případů (studentů), u kterých existuje spoluvýskyt daných hodnot všech tří proměnných zmíněných ve výše naznačeném asociačním pravidle. Dodejme, že ačkoli se metoda asociačních pravidel výrazně rozšířila zvláště po roce 1993 v souvislosti s prací autorů Agrawal, Imieliński a Swami (1993), již v roce 1966 přišli s návrhem obdobné metody automatického získávání pravidel či vztahů čeští autoři Hájek, Havel a Chytil (1966) a tato jejich metoda označovaná zkratkou GUHA (*General Unary Hypotheses Automaton*) je dodnes v oblasti obecného data miningu využívána a rozvíjena.

Tradičním způsobem využití asociačních pravidel a zároveň první oblastí, kde byla asociační pravidla využita, je tzv. analýza nákupního košíku (*market basket analysis*). Tu si lze jednoduše představit jako tabulku nákupů obsahující informaci o tom, jaké všechny produkty byly zakoupeny společně v rámci jednoho nákupu. Pomocí metody asociačních pravidel lze pak získat informaci o tom, jaké produkty jsou obvykle nakupovány společně, což následně prodejce využívá např. pro automatické doporučování určitých produktů při nákupu jiných (v e-shopech), případně pro umístování společně nakupovaných produktů do vzájemné blízkosti (v tradičních kamenných obchodech). Jedním z klasických algoritmů používaných pro dolování asociačních pravidel je pak algoritmus *Apriori* (viz Agrawal, Imieliński, & Swami, 1993). V současnosti je však již využívána i řada dalších algoritmů. V kontextu data miningu ve vzdělávání se obdobný přístup využívá např. v doporučovacích systémech (ať už při doporučování kurzů či konkrétních studijních materiálů), ale také při

řešení specifických problémů jako je např. identifikace testových úloh, u kterých nastává spoluvýskyt chybných odpovědí studentů (srov. Baker & Inventado, 2014; Romero & Ventura, 2007).

Do značné míry blízkou metodou k asociačním pravidlům je metoda **dolování sekvencí** (*sequence mining* či *sequential pattern mining*). I v případě této metody je cílem odhalování důležitých asociací či vztahů. Navíc je však zohledňováno pořadí či časová následnost mezi jednotlivými prvky. Zatímco tedy v případě asociačních pravidel a analýzy nákupního košíku sehrával roli pouze spoluvýskyt (tj. např. které produkty jsou společně v nákupním košíku), v případě dolování sekvencí je důležité i to, jakým způsobem za sebou prvky následují. Jednou z oblastí využití této metody je např. bioinformatika kde se dolování sekvencí využívá při práci s daty obsahujícími sekvence písmen A, G, C a T tvořících DNA. V oblasti data miningu ve vzdělávání lze dolování sekvencí využít zvláště v situacích, kdy nás zajímá způsob průchodu studenta kurzem či způsoby chování studentů v rámci nějaké výukové aktivity.

Vedle dolování sekvencí, které je využíváno jednak v data miningu obecně, jednak v rámci specifických disciplín (např. již zmiňovaná bioinformatika), je v kontextu data miningu ve vzdělávání pro účely analýzy posloupností či sekvencí aktivit uplatňován ještě i jiný metodologický přístup. Jde o tzv. **dolování procesů** (*process mining*), které vychází primárně z oblasti managementu a řízení podnikových procesů, kde se zaměřuje na analýzu procesních dat z různých typů podnikových a manažerských systémů (srov. van der Aalst, 2011, 2016). Dolování procesů je však uvedeno i mezi základními analytickými technikami data miningu ve vzdělávání ve stěžejní publikaci *Handbook of Educational Data Mining* (Romero, Ventura, Pechenizkiy, & Baker, 2010). Zároveň v této oblasti existuje několik studií, které dolování procesů využívají (např. Schoor & Bannert, 2012; Romero, Cerezo, Bogarín, & Sánchez-Santillán, 2016; Papamitsiou & Economides, 2016; Juhaňák, Zounek, & Rohlíková, 2019). Základním úkolem dolování procesů je získávání užitečných informací z dat, které mají procesní charakter (tj. ve své podstatě zachycují nějaký proces). V kontextu systémů typu LMS se přitom ovkykle jedná o tzv. logy.

#### **2.2.1.3.5. Analýza sociálních sítí**

Do výše nastíněné kategorie dolování vztahů by z určitého hlediska bylo možné zařadit i metodu analýzy sociálních sítí (*social network analysis*), jejíž stěžejní součástí je právě zkoumání vztahů mezi jednotlivými aktéry či prvky v rámci dané sítě. Přesto se jeví jako vhodnější hovořit o samostatné kategorii, a to hned z několika důvodů. Předně, analýzu sociálních sítí lze v současné době jen obtížně považovat za jednu dílčí konkrétní metodu. Mnohem spíše lze souhlasit s Wassermanem a Faustovou (1994), že jde o obecnější výzkumnou perspektivu či výzkumný přístup, který zahrnuje relativně širokou škálu metod



zaměřujících se na zkoumání nejrůznějších charakteristik (sociálních) sítí. V současnosti je zároveň analýza sociálních sítí považována za mezioborovou oblast výzkumu, jež zahrnuje výzkumníky z široké škály disciplín jako je sociologie, antropologie, informatika, pedagogika, kriminologie, ekonomie, medicína, epidemiologie, politologie a řada dalších (Scott & Carrington, 2011). Navíc historické kořeny analýzy sociálních sítí lze nalézt spíše v sociologii a teorii grafů (součást matematiky) než v oblasti data miningu. Ve zdrojích týkajících se metod data miningu tak není analýza sociálních sítí příliš často uváděna. Podobně v souvislosti s data miningem ve vzdělávání pak například Baker a Inventado (2014) analýzu sociálních sítí neuvádí mezi základními metodami, přičemž vysvětlují, že z jejich pohledu je analýza sociálních sítí využívána spíše v rámci analytiky učení než v oblasti data miningu ve vzdělávání. Na druhou stranu, řada dalších autorů a výzkumníků v této oblasti považuje analýzu sociálních sítí za součást metodologické výbavy i v oblasti data miningu ve vzdělávání (viz např. Bakhshinategh, Zaiane, ELAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Peña-Ayala, 2014a, Romero & Ventura, 2010).

Analýzu sociálních sítí lze také v určitém ohledu chápat jako podobnou dolování procesů či dolování sekvencí. A to v tom smyslu, že oproti ostatním výše zmiňovaným metodám, se metody jako analýza sociálních sítí a dolování procesů zaměřují na analýzu specifických typů dat. A zatímco dolování procesů se zaměřuje na data zachycující určitý proces, analýza sociálních sítí je schopna analyzovat data, která mají charakter sítě – tj. zachycují určité vztahy mezi určitými prvky. Zároveň je třeba dodat, že tyto metody obvykle nejsou schopny analyzovat data tradičního typu. Za „tradiční“ data lze přitom považovat tabulku tvořenou sloupci v podobě proměnných a řádky reprezentujícími jednotlivé případy, tj. taková data, která jsou běžně analyzována různými metodami jako regrese, klasifikace, shlukování, redukce dimenzí apod. Metody analýzy sociálních sítí či dolování procesů je tak třeba chápat (oproti jiným zmiňovaným metodám) vždy jen jako metody zaměřující se na analýzu specifického typu dat.

Jedním z relativně častých způsobů využití analýzy sociálních sítí v kontextu vzdělávání a online systémů typu LMS je analýza komunikace v online diskuzních fórech (viz např. Hernández-García, González-González, Jiménez-Zarco, & Chaparro-Peláez, 2015; Rabbany, ELAtia, Takaffoli, & Zaiane, 2014; Wise & Cui, 2018). Najdou se ale i jiné způsoby využití. Např. Saqr, Fors a Nouri (2018) využívají analýzu sociálních sítí v kontextu predikce úspěšnosti studentů. Analýza sociálních sítí se rovněž využívá v kontextu skupinové spolupráce a skupinového učení, kde může být příkladem studie autorů Xie, Di Tosto, Lu & Cho (2018), kteří se zaměřili na mapování sociální dynamiky a identifikaci lídrů v rámci skupinového učení. Přitom použili kombinaci analýzy sociálních sítí a metody dolování textů

(viz následující kapitola). Nutno však podotknout, že analýza sociálních sítí bývá mnohem častěji využívána v kontextu analytiky učení spíše než v kontextu data miningu ve vzdělávání. Další příklady výzkumů aplikujících metody analýzy sociálních sítí jsou pak uvedeny v kapitole 2.3.5.1. *Analytika sociálních sítí*, a zvláště pak v sondě B (viz kapitola 5).

### **2.2.1.3.6. Dolování textů a zpracování přirozeného jazyka**

Dolování textů (*text mining*)<sup>57</sup> lze považovat za další velkou skupinu metod data miningu ve vzdělávání ale i analytiky učení. Obecným cílem dolování textu je automatizovaná extrakce relevantních informací z textových dokumentů. Bousbia a Belamri (2014) považují text mining za rozšíření oblasti data miningu o takové metody a techniky, které jsou schopny pracovat s daty v podobě textu. K rozvoji těchto metod pak přispívá nejen oblast data miningu jako takového (příp. oblast strojového učení), ale také např. počítačová lingvistika či oblast označovaná jako zpracování přirozeného jazyka (*Natural Language Processing – NLP*).

Data je v základu možné rozdělit na strukturovaná a nestrukturovaná. Zatímco strukturovaná data mají stanoven určitý systém, na základě kterého jsou ukládána, a tudíž mají ve výsledku jasnou a jednotnou strukturu (typicky v podobě tabulky resp. databáze), nestrukturovaná data takový pevný systém ukládání nemají, a tudíž ve výsledku nemají jednotnou strukturu. Typickým příkladem nestrukturovaných dat mohou být nejrůznější textové dokumenty v přirozeném jazyce (např. e-maily, příspěvky lidí na sociálních sítích, literární díla apod.), ale spadají sem také různé vizuální dokumenty (obrázky, fotografie apod.) či zvukové a audiovizuální dokumenty. Dolování textu a zpracování přirozeného jazyka se pak zaměřuje specificky na zpracování a analýzu těchto nestrukturovaných dat v podobě textu v přirozeném jazyce<sup>58</sup>. Tím se zároveň oblast text miningu odlišuje od obecného data miningu a všech výše zmiňovaných metod, jelikož ty se zaměřují na analýzu strukturovaných dat.

Konkrétní metody a techniky text miningu lze seskupovat do obecnějších skupin podle toho, k čemu slouží, resp. k řešení jakého úkolu se obvykle využívají. Mezi běžné úkoly v rámci text miningu patří například:

- *kategorizace textů* podle tématu či druhu textu,
- *shlukování textů*, při kterém je cílem identifikovat podobné texty,

---

<sup>57</sup> Někdy též „text data mining“ či „text analytics“, viz Romero a Ventura (2013).

<sup>58</sup> To však nevylučuje kombinaci text miningových metod s dalšími uvedenými metodami. Naopak velmi častým způsobem využití metod dolování textu v kontextu konkrétních studií a výzkumů je v první fázi aplikace metod pro zpracování přirozeného jazyka tak, aby z nestrukturovaných dat vznikla data strukturovaná, a v druhé fázi pak aplikace některé z výše popsaných metod pro práci se strukturovanými daty.

- *extrakce jmenných entit*, kdy jsou z textů automaticky extrahována jména lidí, organizací, míst, časových údajů apod.,
- *analýza sentimentu* zaměřující se na názory či pocity vyjadřované v rámci analyzovaných textů či
- *sumarizace textů*, v rámci které dochází k automatické tvorbě krátkých textových shrnutí původních analyzovaných dokumentů (Bousbia & Belamri, 2014; Lang, Siemens, Wise, & Gašević, 2017; Romero & Ventura, 2013).

V kontextu data miningu ve vzdělávání se text mining používá především v souvislosti s analýzou obsahu diskuzních fór či chatů, analýzou textových prací či odpovědí studentů (obvykle za účelem automatického hodnocení či poskytování zpětné vazby) či analýzou obsahu studijních materiálů a zdrojů (obvykle za účelem doporučení vhodného studijního obsahu studentům, srov. Lang, Siemens, Wise, & Gašević, 2017).

#### **2.2.1.3.7. Objevování pomocí modelů**

Zatímco výše uvedené metody a techniky jsou rozšířeny i mimo oblast data miningu ve vzdělávání, metodu označovanou jako objevování pomocí modelů (*discovery with models*) lze považovat za do značné míry specifickou právě v data miningu ve vzdělávání. Jelikož v jiných oblastech aplikace data miningových metod se příliš neuplatňuje (viz Baker & Yacef, 2009; Baker & Inventado, 2014). V základu lze postup objevování pomocí modelů rozdělit do dvou fází. V první fázi je pomocí určitých data miningových metod vytvořen model nějakého fenoménu či konstruktů. V druhé fázi je pak tento model využit jakožto součást jiné analýzy na jiných datech. Jedním z poměrně častých způsobů využití tohoto metodologického přístupu je situace, kdy je nejprve vytvořen úvodní model, a následně jsou predikované hodnoty tohoto výchozího modelu využity jakožto prediktory v nějakém dalším modelu v rámci navazující analýzy. Jiným příkladem je využití počátečního modelu k detekci různých typů studentů či jejich chování v online prostředí, přičemž v následné analýze je věnována pozornost rozdílům mezi dříve identifikovanými skupinami studentů v rámci studovaného problému (např. motivace, úspěšnost apod.). Za do značné míry ukázkový příklad využití této metody lze považovat studii Hershkovitze et al. (2013). Relativně často je tento přístup využíván při modelování chování studentů označovaného *jako gaming the system*<sup>59</sup> (viz např. Baker & Gowda, 2010).

---

<sup>59</sup> Do češtiny by bylo možné termín přeložit jako „obcházení systému“, tj. situaci, kdy student využívá možností systému pro to, aby si např. ulehčil práci, obešel stanovená pravidla, splnil stanovenou aktivitu pouze formálně bez skutečného zapojení apod.

### 2.2.2. Vymezení a konceptualizace analytiky učení

Analytiku učení lze vymežit různými způsoby. Asi nejčastěji přijímanou definicí je definice Siemense, který ji chápe jako disciplínu zabývající se „měřením, sběrem, analýzou a reportováním dat o studentech a jejich kontextech, za účelem pochopení a optimalizování učení a prostředí, ve kterých učení probíhá“ (Long & Siemens, 2011, s. 34)<sup>60</sup>. Jak je patrné, tato definice zřetelně navazuje na tradici webové analytiky, když se zaměřuje přímo na vzdělávací prostředí a jeho optimalizaci. Na druhou stranu však odhlíží od technických specifik a zdůrazňuje výhradně pedagogickou stránku. Nespojuje rovněž analytiku učení s konkrétními dříve ustanovenými oblastmi, nýbrž ji vymezuje jako svébytnou disciplínu.

Zároveň je třeba zdůraznit, že Siemensova definice neomezuje analytiku učení pouze na online prostředí, jako to dělají jiní autoři. Např. Chatti et al. (2012) či Fergusonová (2012a) chápou analytiku učení jako do značné míry dílčí výzkumnou oblast v rámci e-learningu, která se týká výhradně učení v online prostředí. Takové pojetí analytiky učení je však v dnešní době možné vnímat jako příliš úzké. Ačkoli se zřejmě většina výzkumníků i dnes věnuje analytice učení v online vzdělávacích systémech, existují již příklady využití analytiky učení i v off-line vzdělávacím prostředí např. ve školní třídě. Lze uvést autory D'Mello (2017) či Ochoa (2017), kteří zmiňují příklady výzkumů toho, kam se studenti v průběhu výuky dívají, analýzy postojů, gest a pohybů či analýzy výrazů tváře studentů v průběhu učení či plnění vzdělávací aktivity. V tomto kontextu se pak hovoří o oblastech jako *Emotional Learning Analytics*, *Classroom Learning Analytics* či *Multimodal Learning Analytics*.

#### 2.2.2.1. Úroveň analytiky ve vzdělávání

Výše uvedená Siemensova definice však postihuje pouze jednu z úrovní, o kterých je možné v souvislosti s analytikou ve vzdělávání uvažovat. Podle Buckingham Shum (2012) lze přitom rozlišovat tři základní úrovně analytiky ve vzdělávání.

**Mikroúroveň** se zaměřuje na individuální studenty či skupiny studentů<sup>61</sup>. Na této úrovni jde o sběr a analýzu dat, která za sebou nechávají jednotliví uživatelé při používání různých systémů či služeb. Nejčastěji jde o záznamy ze vzdělávacích informačních systémů (EIS) zahrnujících např. absolvované předměty či získané známky a o záznamy aktivit studentů v online výukovém prostředí (např. LMS). Taková data přitom umožňují zjistit, jaké studijní materiály si student zobrazil, jak dlouho mu trvalo nějaké cvičení apod. Může však jít i o další

---

<sup>60</sup> Originální znění: „learning analytics is the measurement, collection, analysis and reporting of data about learners and their contexts, for purposes of understanding and optimising learning and the environments in which it occurs.“ (Long & Siemens, 2011, s. 34).

<sup>61</sup> Hovořím zde sice primárně o studentech, uvedené se však může týkat i žáků.

typy dat týkajících se studentů, např. výpůjčky v knihovně, sociální síť kontaktů, záznamy o pohybu studenta získané pomocí geolokace aj. Výsledky analýz na mikroúrovni jsou přínosné především pro učitele. Mohou však být užitečné i pro samotné studenty, kterým dokážou poskytovat vhled do vlastních (třeba neuvědomovaných) učebních návyků a podporovat tak reflexi vlastního učení.

**Mezoúroveň** je úrovní vzdělávacích institucí, na níž je hlavním cílem analytiky učení optimalizace administrativních a organizačních procesů v rámci vzdělávací instituce. Data pocházejí primárně z nejrůznějších ekonomických, správních či manažerských systémů, často však bývají doplňována o data z dalších specifických systémů, které daná instituce využívá. V případě univerzit jsou to zvláště systémy schraňující data o výzkumné a publikační činnosti apod. Výsledky analytiky na mezoúrovni mohou být přínosné především pro administrativu, management a vedení vzdělávací instituce, ale také pro investory či donátory a další zainteresované strany.

**Makroúroveň** pak odpovídá regionální, státní, národní či mezinárodní úrovni. Zde tedy jde spíše již o meziinstitucionální či nadinstitucionální úroveň, kde analytika může hrát důležitou roli jednak pro jednotlivé vzdělávací instituce, jednak pro nejrůznější regionální a státní školské orgány, národní vlády či mezinárodní organizace.

Na základě výše uvedeného členění analytiky ve vzdělávání je patrné, že Siemensem navrhovaná definice odpovídá mikroúrovni. Je proto nutné rozlišovat užší a širší význam pojmu „analytika učení“. V užším významu se pohybujeme pouze na mikroúrovni, v širším významu pod tento pojem spadají všechny uvedené úrovně. Z důvodu přesnosti by proto bylo vhodnější oba významy explicitně rozlišovat (např. analytika učení vs. analytika vzdělávání). V dosavadních zdrojích však toto rozlišení není dodržováno a využívá se pouze označení analytika učení (*learning analytics*).

Zároveň vidíme, že mezoúroveň do značné míry odpovídá tomu, co bylo výše identifikováno jako jedna ze souvisejících oblastí, totiž akademická analytika. Stejně tak Long a Siemens (2011) rozlišují mezi akademickou analytikou a analytikou učení právě na základě toho, že akademická analytika se zaměřuje na úroveň institucí a výše (tj. mezoúroveň plus makroúroveň), zatímco analytika učení zahrnuje úroveň jednotlivých kurzů (tj. mikroúroveň). V takovém případě můžeme analytiku vzdělávání (tj. analytiku učení v širokém smyslu) chápat jako spojení akademické analytiky a analytiky učení v úzkém smyslu.

Je však třeba zároveň upozornit, že výše uvedené pojmy a jejich rozlišení není zatím široce ukotveno a je možné, že se bude postupem času dále měnit, zpřesňovat či rozšiřovat. Označení „akademická analytika“ jasně odkazuje k místu svého vzniku, totiž akademickému prostředí

univerzit. Lze ovšem očekávat rozšíření analytiky i mimo univerzitní prostředí, proto je možné, že se v budoucnu rozšíří obecnější pojem, který by nezahrnoval jen akademickou sféru (např. institucionální analytika). Zároveň se již dnes hovoří o analytice učení v kontextu profesního vzdělávání a informálního učení (viz např. Littlejohn, 2017), přičemž se využívá označení *Professional Learning Analytics*. V časopise *Journal of Research in Innovative Teaching & Learning* pak v roce 2017 vyšlo speciální číslo zaměřující se mimo jiné na analytiku učení v kontextu primárního a sekundárního vzdělávání (název čísla zněl *Learning Analytics in primary, secondary and higher education*, viz tabulka 1). Lze proto očekávat, že s rozšiřováním analytiky učení do nových oblastí se budou objevovat i další specifická označení konkrétních směrů výzkumu a aplikace analytiky ve vzdělávání.

### 2.2.2.2. Proces analytiky učení

Jak již bylo naznačeno, analytika učení podobně jako akční výzkum bývá konceptualizována v podobě opakujícího se cyklu obsahujícího několik fází. Doposud však není obecně přijímáno jedno konkrétní pojetí analytického cyklu (*learning analytics cycle*) a rozlišování jednotlivých fází cyklu se tak u různých autorů liší. Tak například Campbell a Oblinger (2007) představili cyklus akademické analytiky v pěti krocích zahrnujících *získávání dat, informování, predikování, jednání* a následné *zlepšování*. Chatti et al. (2012) později zúžili

Tabulka 3: Srovnání různých konceptualizací procesu analytiky učení.

<b>Campbell &amp; Oblinger, 2007</b>	<b>Chatti et al., 2012</b>	<b>Siemens, 2013</b>	<b>Lal, 2014</b>
získávání	sběr dat a předzpracování (pre-processing)	sběr a akvizice ukládání čištění integrace	získávání dat strukturování a agregování dat
informování		analýza	analyzování
predikování	analýzy a akce	zobrazení a vizualizace	zobrazování a vizualizace
jednání			akce
zlepšování	následné zpracování (post-processing)	akce	zlepšování

počet etap jen na tři, zatímco Siemens (2013) naopak uvádí cyklus až o sedmi fázích, když podrobněji rozlišuje různé fáze zpracování dat předcházející samotné analýze. Lal (2014) se pak pokouší o určité sjednocení předchozích přístupů a uvádí fází šest. Srovnání zmíněných pojetí procesu analytiky učení je možné vidět v tabulce 3.

Vzhledem k tomu, že zatím žádná z konceptualizací není všeobecně přijímána, popíši cyklus analytiky učení obecně ve čtyřech základních krocích:

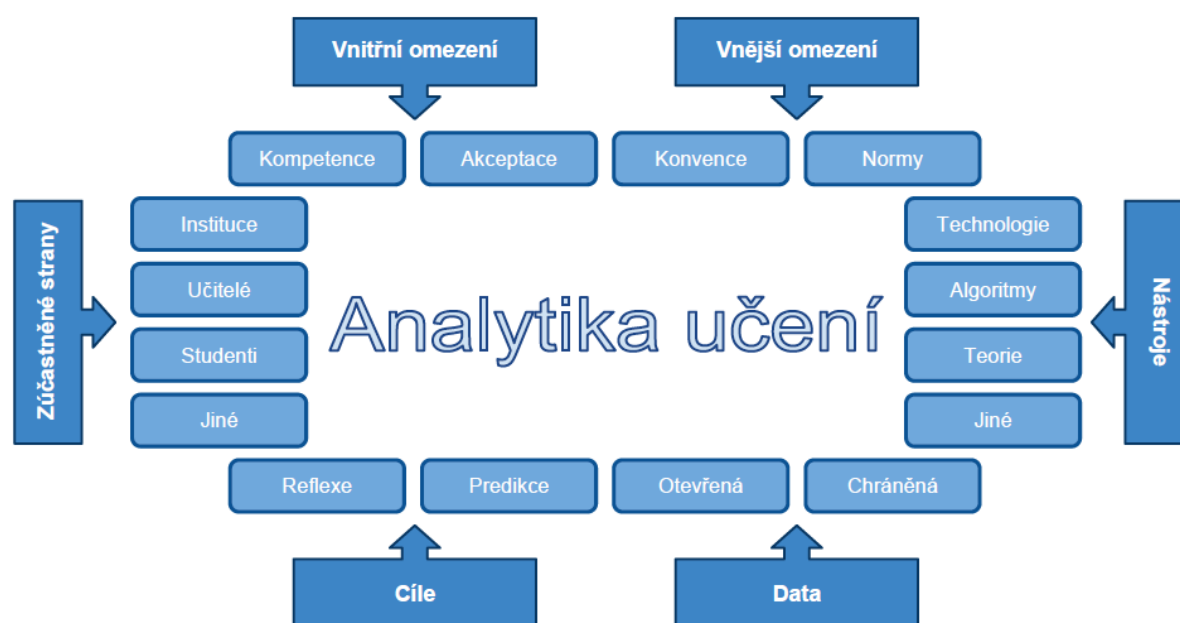
- 1. Sběr a zpracování dat** samozřejmě záleží na tom, co je v daném případě naším cílem a jaké otázky si pokládáme. Campbell a Oblinger (2007) uvádějí poměrně rozsáhlý výčet typů dat, která mohou být ve vzdělávacích institucích dostupná. Od demografických dat, přes výsledky studia až po chování žáků či studentů v konkrétních kurzech. Pozornost je však nutné věnovat i tomu, která data zatím sbírána nejsou, ale mohla by být pro naše účely potenciálně užitečná. Získaná data je následně nutné předzpracovat a případně převést do potřebných formátů. Stěžejní roli zde hraje čištění dat. Pro komplexnější pohled na zkoumaný fenomén může být využita integrace dat z několika různých zdrojů (Siemens, 2013).
- 2. Analýza a vizualizace** je druhou fází analytického procesu. V této fázi jsou používány různé metody a techniky ke zkoumání získaných dat, za účelem objevení potenciálně užitečných informací a jejich následné prezentace (často v podobě vizualizace) zúčastněným stranám. Co se týče využívaných metod, Lal (2014) je v kontextu analytiky učení rozděluje do tří hlavních oblastí: *základní statistické metody*, *data miningové metody*, kde jde především o klasifikaci, klastrování a asociační pravidla a *metody sociální analytiky učení*, kam lze zařadit např. analýzu sociálních sítí, obsahovou analýzu či analýzu diskurzu.
- 3. Akce** zde znamená zásah do edukační reality, který je proveden určitou zainteresovanou stranou na základě výsledků analýz, které jí byly prezentovány. Akce přitom může mít nejrůznější charakter. Může jít o jednoduché oznámení, upozornění či varování, ale také o komplexnější formu intervence do současné podoby edukační reality. Tak může být student například automaticky upozorněn na to, že v porovnání s ostatními je výrazně pozadu. Anebo může být naopak upozorněn učitel, který následně sám zvolí vhodný způsob intervence. Akcí může být také optimalizace stávajícího výukového systému či jiné systémové úpravy či vylepšení. V případě adaptivních systémů lze za akci považovat přizpůsobení či personalizaci, která je vykonána na základě výsledku provedených analýz. U doporučovacího systému lze za akci považovat automatické doporučení

vhodného rozšiřujícího studijního materiálu (Chatti et al., 2012; Lal, 2014, Siemens, 2013).

4. **Reflexe a revize** označují poslední etapu cyklu, kdy probíhá zhodnocení či evaluace provedené akce a zároveň plánování dalšího cyklu. Může tak jít např. o sběr jiných dat nebo doplnění dat stávajících. Stejně tak může jít o provedení doplňujících analýz, volbu jiných analytických metod či vykonání jiných akcí na základě provedených analýz (srov. Campbell & Oblinger, 2007; Chatti et al., 2012).

### 2.2.2.3. Dimenze analytiky učení

Aby bylo možné analytiku učení v rámci vzdělávací organizace efektivním způsobem využít, je třeba zohlednit řadu důležitých faktorů. Především, proces analytiky učení vyžaduje zapojení několika odlišných oblastí expertízy, což vyžaduje nejen zapojení velkého množství expertů z různých oblastí, nýbrž také spolupráci několika jinak oddělených součástí (či oddělení) v rámci jedné instituce. Greller a Drachsler (2012) tak navrhují obecný rámec analytiky učení zahrnující šest různých dimenzí, kterým musí být v rámci vzdělávací instituce věnována pozornost, má-li být dosaženo efektivního zapojení a využívání analytiky učení.



Obrázek 10: Obecný rámec zahrnující šest základních dimenzí analytiky učení (podle Greller & Drachsler, 2012).

V prvním kroku můžeme hovořit o **cílech** využití analytiky učení v rámci dané vzdělávací instituce (srov. obrázek 10 výše). Smyslem analytiky učení je dle Grellera a Drachslera (2012) odhalování skrytých informací a souvislostí ve vzdělávacích datech a jejich následné



zpracování pro různé zúčastněné strany. Autoři přitom rozlišují dva základní cíle: *reflexi* a *predikci*. Reflexí je míněna především sebe-evaluace. Analytika učení je zde prostředkem pro získání lepšího vhledu do vlastního jednání. Například můžeme pomocí určitého nástroje vizualizovat chování studentů či učitelů v online kurzu, což jim dá možnost reflektovat, zda jejich učení resp. vyučování probíhá podle jejich představ a cílů. Predikce se pak nachází ještě o krok dál, kdy analytika učení spočívá v modelování chování studentů, což umožňuje např. upozorňovat učitele konkrétně na ty studenty, kteří mohou mít na základě odpovídajícího modelu určitý problém se studiem. Učitel tak má podklady k tomu, aby mohl např. s daným studentem pracovat individuálně, nebo mu nabídnout jinou formu podpory při učení, a zabránit tak neúspěchu studenta na konci kurzu.

Za další dimenzi můžeme považovat různé **zúčastněné strany**. U analytiky učení lze vždy rozlišovat několik zúčastněných stran. Od studentů, přes učitele, až po vedení instituce či jiné zúčastněné strany (např. investory, donátory, grantové agentury). Sclater (2017) vyjmenovává až 11 různých skupin tzv. stakeholderů, kteří do analytického procesu vstupují. Vedle výše uvedených lze podle Sclatera zmínit také:

- IT podpora (*IT Services*). Zajišťují správu vzdělávacího systému, mají na starost vývoj či přizpůsobení (*customization*) technického řešení pro sběr, správu a vizualizaci dat apod.
- Tvůrce kurzů (*Learning designer*). Podílí se na designu kurzů a na tom, jakým způsobem se v nich bude promítat analytický nástroj.
- Datový analytik (*Data scientist*). Spolupracuje na návrhu a vývoji analytického systému. Provádí analýzy sbíraných dat, evaluuje fungování analytického systému, podílí se na tvorbě prediktivních modelů, zajišťuje validování modelů apod.
- Výzkumník v oblasti pedagogiky (*Educational researcher*). Do procesu návrhu a vývoje analytického systému, stejně jako následně do jeho evaluace může zasahovat rovněž odborník na pedagogický výzkum. Stejně tak se může podílet i na návrhu formy intervence do edukační reality na základě realizovaných analýz.
- Tutor kurzu (*Tutor*). Zajišťuje podporu studentům přímo v kurzu, monitoruje jejich postup kurzem, a případně může navrhnout vylepšení kurzu či analytického nástroje na základě jeho využívání studenty.

To, které zúčastněné strany jsou v konkrétním případě zapojeny, samozřejmě následně ovlivňuje zbývající dimenze analytiky učení.

V závislosti na stanovených cílech a zúčastněných stranách je v rámci další dimenze nutné věnovat pozornost získávaným a analyzovaným **datům**. Greller a Drachsler (2012) přitom

rozlišují data na *otevřená* a *chráněná*, v čemž můžeme spatřovat jejich důraz na etické aspekty práce s daty. V souvislosti s daty je však nutné věnovat pozornost i tomu, jaké typy dat jsou vlastně v rámci instituce k dispozici, jaká další data by v případě potřeby bylo možné dále sbírat, jak jsou data zpracovávána a uchovávána apod.

Od dostupných dat se pak odvíjí použité **nástroje** či prostředky. Mezi nástroje/prostředky zahrnují autoři nejen samotné technologie a konkrétní technická řešení, ale také využití algoritmy, metody analýzy, a dokonce i celé teorie či teoretické přístupy. Některé konkrétní nástroje analytiky učení jsou pak zmíněny a podrobněji popsány v následujících kapitolách (zvláště pak v kapitole 2.3.1. *Analytické nástroje pro sumarizaci a vizualizaci dat*).

Poslední dvě dimenze v modelu Grellera a Drachslera (2012) tvoří vnitřní a vnější omezení. **Vnitřní omezení** vycházejí z možností, limitů a zdrojů instituce, která chce analytiku učení využívat. Zásadní je zde oblast *kompetencí*, jelikož kvůli své multidisciplinární povaze vyžaduje analytika učení pro své efektivní fungování nové typy kompetencí (především v souvislosti s moderními technologiemi – typicky programování nebo pokročilá analýza dat). Nedílnou součástí je pak i *akceptace* analytiky učení napříč zúčastněnými stranami. **Vnější omezení** pak autoři modelu dělí na *konvence*, které zahrnují především etiku, a *normy*, jež spojují s právem a konkrétní legislativou. Vzdělávací instituce se také vždy pohybují v určitém společenském a právním kontextu, na který musí brát ohled. Při využití analytiky ve vzdělávacím kontextu je přitom specifické to, že mnoho etických ale i právních otázek zatím nebylo díky novosti problematiky ani položeno, natož zodpovězeno.

### 2.2.3. Srovnání data miningu ve vzdělávání a analytiky učení

V předchozích dvou kapitolách jsem zvlášť představil oblast data miningu ve vzdělávání a oblast analytiky učení. Přestože byly obě zmiňované oblasti představeny a popsány zvlášť a se zaměřením na různé aspekty, byly čtenáři jistě patrné značné podobnosti a výrazné styčné plochy mezi těmito výzkumnými oblastmi. V obou případech jde o relativně mladá výzkumná pole, která se zaměřují na využití dat z různých typů vzdělávacích systémů, přičemž hlavní pozornost je věnována online výukovým systémům. Pro analýzu těchto dat přitom obě oblasti využívají do značné míry obdobné metody, techniky a analytické postupy. Data mining ve vzdělávání i analytika učení se tak zaměřují na využití obdobných typů dat pocházejících z obdobných typů vzdělávacích systémů za využití obdobných metod analýzy.

Rovněž širší kontext a koncepty používané v analytice učení a data miningu ve vzdělávání vzájemně korespondují. Hlavním příkladem může být konceptualizace procesu data miningu ve vzdělávání resp. analytiky učení. V obou případech je tento proces pojímán iterativně jako cyklus obsahující získávání dat ze vzdělávacího prostředí, jejich zpracování a analýzu

a následné využití či aplikaci výsledků analýz zpětně v rámci daného vzdělávacího prostředí. Podobně můžeme v obou oblastech uvažovat o různých úrovních, na kterých je možné analýzy realizovat. Při aplikaci data miningu ve vzdělávání stejně jako u využívání analytiky učení je přitom do analytického procesu zapojena řada různých zúčastněných stran od samotných výzkumníků, přes studenty a vyučující až po tvůrce kurzů, tutorů či správce výukových systémů.

V neposlední řadě je i základní cíl obou oblastí do značné míry stejný. Obě disciplíny totiž usilují jednak o využití výše zmiňovaných dat a analytických postupů pro pochopení a porozumění procesu učení v různých vzdělávacích prostředích a systémech, jednak o následné optimalizování daných výukových systémů tak, aby se v nich mohli studenti efektivněji učit a učitelé v nich mohli lépe vyučovat.

Všechny výše uvedené podobnosti mezi analytikou učení a data miningem ve vzdělávání byly poměrně podrobně nastíněny v předchozích dvou kapitolách a jsou tudíž, jak věřím, dostatečně zřejmé. Co však může být již výrazně méně zřejmé, jsou odlišnosti mezi těmito výzkumnými oblastmi. Zda se tyto oblasti vůbec nějakým zásadním způsobem liší, a pokud ano, na základě čeho je možné odlišit jednu od druhé. Následující podkapitoly proto věnují hlavním rozdílům, které lze mezi analytikou učení a data miningem ve vzdělávání nalézt.

### **2.2.3.1. Rozdílný vznik a vývoj v čase**

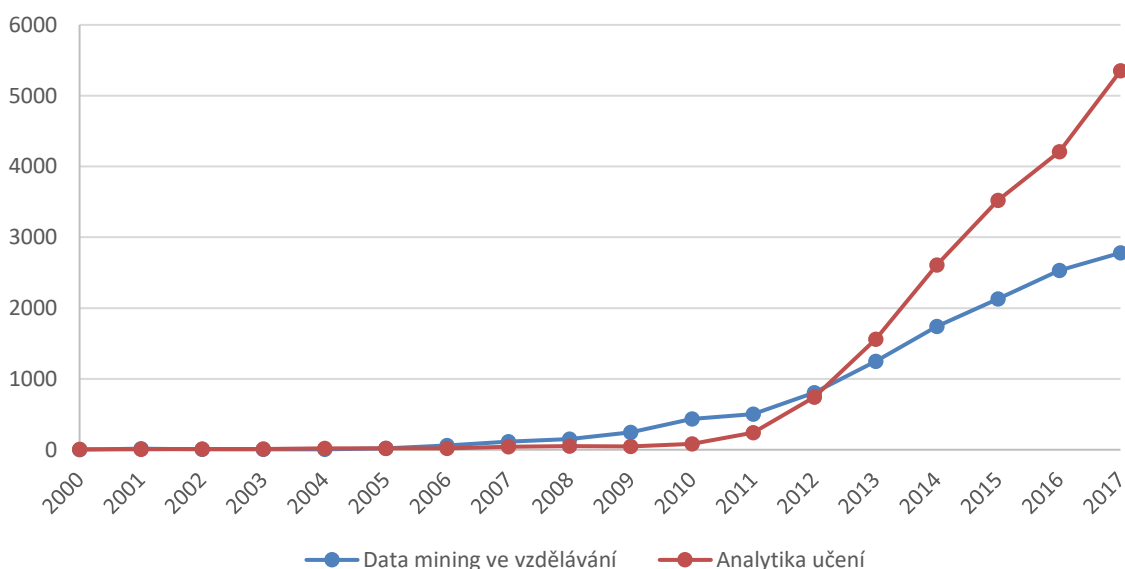
Vzniku a historickým kořenům data miningu ve vzdělávání a analytiky učení již byla věnována podrobná pozornost v kapitole 2.1. Lze proto jen shrnout, že obě disciplíny vychází z poněkud odlišného kontextu a na jejich formování se podílely jiné oblasti. Zatímco data mining ve vzdělávání vychází primárně z obecného data miningu a databázových systémů, přičemž má blízko rovněž k oblasti umělé inteligence a oblasti strojového učení, analytika učení čerpá především z webové analytiky a podnikové analytiky resp. *business intelligence*. Siemens a Baker (2012) doplňují, že data mining ve vzdělávání má blízko především k vývoji vzdělávacího softwaru a modelování uživatelů (studentů), kdežto analytika učení spojují spíše s oblastí sémantického webu a problematikou tzv. inteligentního kurikula (*intelligent curriculum*) a systemických intervencí (*systemic interventions*).

Do značné míry odlišná je i doba vzniku, a především pak následující vývoj obou oblastí v čase. Jak již bylo zmíněno, vznik data miningu ve vzdělávání jakožto svébytné výzkumné oblasti bývá spojován s přelomem let 2008 a 2009. Diskuze a určité výzkumné snahy lze však v souvislosti s touto oblastí nalézt přinejmenším již v roce 2005, přičemž dílčí pokusy o využití data miningu v kontextu vzdělávání se objevují i dále v minulosti (Romero & Ventura, 2007). Naopak pojem analytiky učení odkazující k nově se vyčleňující výzkumné

oblasti se objevil poměrně náhle na přelomu let 2010 a 2011. Analytika učení se tak začala rozvíjet o několik let později, a i v současnosti je stále poměrně mladým výzkumným polem.

Zároveň však analytika učení i přes pozdější vznik zažívá výrazně mohutnější rozvoj než data mining ve vzdělávání. To ilustrují následující dva grafy zaměřující se na četnost výskytu jednotlivých disciplín (tj. frází „learning analytics“ resp. „educational data mining“) v odborných publikacích. Konkrétně byl využit webový vyhledávač odborných textů Google Scholar, v rámci kterého byly pro roky 2000 až 2017 vyhledány počty publikací, v nichž se kdekoli v textu dokumentu (obrázek 11) a následně pouze v názvu dokumentu (obrázek 12) vyskytují klíčová slova „learning analytics“ resp. „educational data mining“.

Počty nalezených výsledků zmiňujících analytiku učení a data mining ve vzdělávání kdekoli v dokumentu



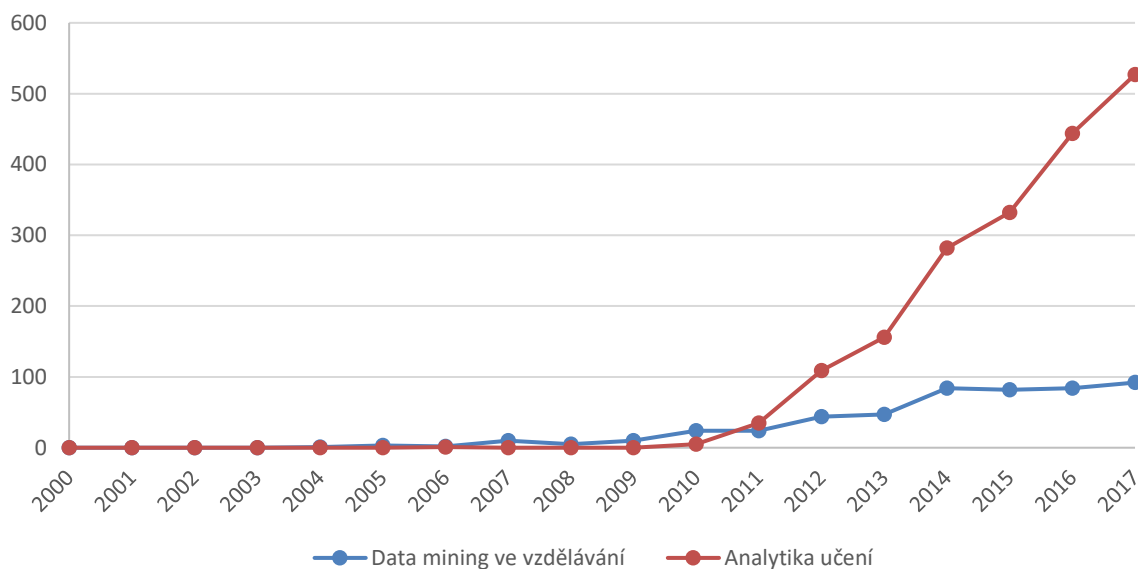
Obrázek 11: Počty nalezených výsledků v rámci Google Scholar zmiňujících analytiku učení a data mining ve vzdělávání dle jednotlivých let. Výskyt hledaného termínu „learning analytics“ resp. „educational data mining“ není omezen (tj. může se objevit kdekoli v dokumentu).

Z obou grafů je patrné, že o oblasti data miningu ve vzdělávání se v odborných publikacích začíná hovořit dříve. Jakmile se však kolem let 2010/2011 objevuje analytika učení, tak okamžitě začíná přitahovat pozornost výzkumníků, a po roce 2012 už z hlediska počtu zmínek v odborné literatuře převyšuje oblast data miningu ve vzdělávání. Přestože jde jen o ilustrační čísla, trend rozdílného vývoje obou oblastí je patrný. Budeme-li vycházet z výskytu označení jednotlivých disciplín v názvech odborných publikací (viz obrázek 12), pak lze říct, že k roku 2017 je „popularita“ analytiky učení mezi výzkumníky několikanásobně vyšší ve srovnání

s oblastí data miningu ve vzdělávání. K obdobným záměrům docházejí i Calvet Liñán a Juan Pérez (2015), kteří ovšem tento vývoj mapují pouze do roku 2014.

Mimo dále zmiňované odlišnosti může k vyšší popularitě analytiky učení přispívat právě to, jakým způsobem vznikala resp., jaké další oblasti se podílely na jejím formování. Zatímco oblast data miningu ve vzdělávání vychází především z obecného data miningu, který lze považovat do značné míry za technický obor<sup>62</sup>, na formování analytiky učení se podílelo širší spektrum dalších i netechnicky orientovaných oblastí. Zřejmě díky tomu je i dnes analytika učení více přístupná výzkumníkům z různých vědních disciplín, a tudíž je ve větším množství zmiňována v odborných publikacích. S tím souvisí i fakt, že v rámci analytiky učení rovněž působí mnohem více netechnicky zaměřených výzkumníků, například výzkumníci pocházející primárně ze sociálních věd jako psychologie, sociologie či pedagogika (srov. Bienkowski, Feng, & Means, 2012).

Počty nalezených výsledků zmiňujících analytiku učení a data mining ve vzdělávání v názvu dokumentu



Obrázek 12: Počty nalezených výsledků v rámci Google Scholar zmiňujících analytiku učení a data mining ve vzdělávání dle jednotlivých let. Výskyt hledaného termínu „learning analytics“ resp. „educational data mining“ je omezen pouze na název dokumentu.

<sup>62</sup> Data mining bývá obvykle chápán jako dílčí disciplína či výzkumné pole v rámci informatiky (*computer science*).

### **2.2.3.2. Rozdílné využívání analytických metod a technik**

Ačkoli se používané analytické metody a techniky v rámci data miningu ve vzdělávání a analytiku učení do značné míry překrývají, můžeme zde přesto nalézt určité odlišnosti v tom, na jaké metody a techniky je kladen větší či menší důraz (srov. Baker & Inventado, 2014; Romero & Ventura, 2013; Siemens & Baker, 2012). Pokud bychom vyšli ze základního přehledu používaných metod, jak byl představen v jedné z předchozích kapitol (viz kapitola 2.2.1.3.), pak lze říci, že v oblasti data miningu ve vzdělávání převažuje používání prediktivních metod a technik, zvláště pak různé techniky klasifikace. Dále je typické využívání široké škály různých technik shlukování, ale také metod dolování vztahů a objevování pomocí modelů. Naopak v analytice učení jsou dominantní metody jako analýza sociálních sítí či různé postupy založené na zpracování přirozeného jazyka (např. analýza sentimentu, analýza diskurzu, analýza obsahu apod.). V rámci analytiku učení jsou rovněž častěji využívány metody a techniky tradiční statistiky.

Data mining ve vzdělávání je více zaměřen na rozvoj technik pro získávání užitečných informací z dat a vývoj nových algoritmů či modelů, zatímco v kontextu analytiku učení je častěji věnována pozornost aplikaci již existujících postupů v konkrétních vzdělávacích kontextech. S tím souvisí i to, že v analytice učení je kladen větší důraz na analýzu a popis samotných dat, zatímco v data miningu ve vzdělávání výzkumníci častěji věnují pozornost i popisu a srovnávání různých technik za účelem identifikace těch, které si v daném kontextu či při řešení daného problému vedou nejlépe.

Výše nastíněný důraz na určité skupiny metod a technik, ale také důraz na popis samotných dat versus rozvoj metod analýzy, je mimo jiné reflektován v tom, jakou roli ve zmíněných oblastech hraje lidský úsudek, nebo naopak automatizace. Analytika učení je více zaměřená na tzv. daty řízené rozhodování (*data-driven decision-making*), kde je cílem využít možnosti analýzy dat pro získání informací potenciálně důležitých pro účely rozhodování. V takovém rozhodování se přitom uplatňuje především lidský úsudek, zatímco různé automatizované techniky se mohou uplatňovat spíše v rámci získávání informací z dat. Čili automatizované techniky analýzy dat jsou pouze prostředkem k tomu, aby bylo možné provádět lepší rozhodování na základě lidského úsudku. V rámci data miningu ve vzdělávání je naopak automatizace často samotným cílem, kdežto lidský úsudek je prostředkem, jak se k tomuto cíli dopracovat. Tzn., že je cílem dosáhnout automatizace určitého úkolu (např. doporučení vhodného obsahu ke studiu, volba otázky odpovídající náročnosti v rámci adaptivního testovacího systému apod.) a lidský úsudek je zapojen při dosahování tohoto cíle (tj. volba přístupu k řešení, volba použitých analytických metod atd.).

Obecně lze říci, že v rámci data miningu ve vzdělávání je kladen větší důraz na rozvoj a používání metod, které mohou být využity pro účely vývoje prediktivních a adaptivních systémů. Naopak analytika učení akcentuje ty metody, které jsou přínosné z hlediska poskytnutí vhledu do dat. Analytika učení tak cílí především k tomu, aby za využití různých analytických metod a technik bylo možné poskytovat potenciálně důležité informace jednotlivým zúčastněným stranám (studentům, učitelům, vedení vzdělávací organizace, administrátorům daného online vzdělávacího prostředí apod.).

### **2.2.3.3. Rozdílné zaměření pozornosti**

S rozdílným vznikem a různými historickými kořeny stejně jako s odlišným důrazem na využívané analytické postupy souvisí i rozdílný způsob, jakým výzkumníci v data miningu ve vzdělávání a v analytice učení zaměřují svou pozornost při řešení výzkumných problémů a otázek. Siemens a Baker (2012) v této souvislosti hovoří o rozdílném převažujícím přístupu či paradigmatu, které je v těchto oblastech uplatňováno a které v jedné či druhé oblasti převažuje.

Dle Siemense a Bakera (2012) převažuje v oblasti data miningu ve vzdělávání spíše redukcionistický přístup, při kterém výzkumníci postupují tak, že redukuje či zjednodušují zkoumané komplexní jevy na dílčí, a co možná nejjednodušší části, které daný jev tvoří. Následně pak věnují pozornost těmto jednotlivým částem a analyzují vztahy mezi nimi. Jako typický příklad takového redukcionistického přístupu uvádějí zmiňovaní autoři výše popisovanou metodu objevování pomocí modelů (viz kapitola 2.2.1.3.7.). Oproti tomu v analytice učení je podle Siemense a Bakera (2012) běžnější holistický přístup, v rámci kterého výzkumníci usilují o porozumění zkoumanému jevu jakožto celku. Holistický přístup obecně staví na tom, že systém jako celek nelze zcela vysvětlit zaměřováním se pouze na jeho části. Proto i v rámci analytiky učení je mnohem více zdůrazňován širší kontext zkoumaného problému či jevu. Zároveň jsou zohledňovány různé úrovně, kterých se zkoumaný problém dotýká, příp. je výzkumný problém řešen s ohledem na různé zúčastněné strany.

I přes všechny výše zmiňované odlišnosti je však třeba mít na paměti to, že jde stále o do značné míry překrývající se výzkumné oblasti. Jak upozorňují Siemens a Baker (2012) či Baker a Inventado (2014), výše uváděné odlišnosti odpovídají spíše širším trendům či přístupům v analytice učení a data miningu ve vzdělávání. Nelze je tedy chápat jako definiční charakteristiky jednotlivých oblastí. Řada výzkumníků z oblasti analytiky učení může provádět výzkum, který by na základě výše uvedených odlišností mohl lépe zapadat do oblasti data miningu ve vzdělávání a naopak. Nastíněné odlišnosti je tak nutno chápat spíše jako

obecné zaměření jednotlivých oblastí, které však nemusí být platné na úrovni konkrétních výzkumníků či konkrétních realizovaných výzkumů.

### 2.3. Dosavadní směry výzkumů a řešená témata

V této části jsou představeny vybrané výzkumné směry a témata, kterým je v rámci analytiky učení a data miningu ve vzdělávání věnována hlavní pozornost výzkumníků. Vzhledem k tomu, že je cílem této kapitoly podat obecný přehled o dění v jednotlivých řešených oblastech, neusiluje tato část o systematický přehled, nýbrž se zde záměrně zaměřuji pouze na ty směry a ta témata, která lze v analytice učení a data miningu ve vzdělávání považovat za nejvíce akcentovaná či aktuální. Opírám se přitom jednak o řadu přehledově orientovaných publikací (především Baker & Inventado, 2014; Baker & Yacef, 2009; Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Buckingham Shum & Ferguson, 2012; Dutt, Ismail, & Herawan, 2017; Lang, Siemens, Wise, & Gašević, 2017; Papamitsiou & Economides, 2014; Peña-Ayala, 2014b, 2017; Romero & Ventura, 2007, 2010, 2013; Siemens, 2013), jednak také zohledňuji témata, která se s vyšší frekvencí objevují v rámci mezinárodních konferencí zaměřených specificky na tyto oblasti<sup>63</sup>.

Zároveň není možné alespoň z části nezmínit i určitý vývoj, kterým obě oblasti v průběhu posledních let prošly. Vezmeme-li si za příklad analytiku učení, pak lze říci, že v počátcích bylo množství výzkumů a publikací spojeno spíše s vývojem konkrétních analytických či vizualizačních nástrojů, a teprve později se začala pozornost postupně přesouvat ke složitějším prediktivním nástrojům a obecně k hledání možných prediktorů (ne)úspěchu ve studiu. Současně si mnozí autoři začali uvědomovat širší souvislosti fenoménu učení s využitím moderních technologií a snaží se proto přesunout pozornost např. k jeho sociálním či emočním aspektům. Postupem času také sílí důraz na etické aspekty využívání analytiky ve vzdělávání, kterým v počátcích byla pozornost věnována spíše sporadicky. Obdobný vývoj je patrný i v oblasti data miningu ve vzdělávání. V následujících podkapitolách se tak alespoň dílčím způsobem snažím reflektovat a nastínit i dosavadní vývoj jednotlivých směrů a témat výzkumu. Zároveň podávám informaci o tom, nakolik je daná oblast relevantní spíše pro data mining ve vzdělávání, nebo naopak pro analytiku učení. Ovšem s ohledem na značný průnik mezi oběma oblastmi (viz kapitola 2.2.3) je třeba počítat s tím, že v řadě případů se jednotlivé směry výzkumů promítají více či méně do obou oblastí.

---

<sup>63</sup> V oblasti data miningu ve vzdělávání jde primárně o konferenci s názvem *International Conference on Educational Data Mining*, v rámci analytiky učení jde především o konferenci s názvem *International Learning Analytics and Knowledge Conference*.



Než pak přesunu pozornost přímo k jednotlivým výzkumným směrům, je nutné doplnit, že jak data mining ve vzdělávání, tak i analytika učení jsou orientovány výrazně prakticky či aplikačně. Tím je myšleno to, že řada výzkumů v této oblasti je zároveň spojena s vývojem určitého analytického nástroje. Proto je v následující tabulce (viz tabulka 4) nejprve podán stručný přehled analytických a vizualizačních nástrojů či systémů, které jsou v tomto kontextu využívány a kterým je zároveň věnována určitá výzkumná pozornost. Na jednotlivé nástroje uvedené v tabulce je pak dále odkazováno v navazujících podkapitolách.

Některé další analytické nástroje ale i příklady využití analytických systémů na institucionální či národní úrovni zmiňuje Fergusonová et al. (2016). Přehled vybraných nástrojů z oblasti data miningu ve vzdělávání uvádí ve své studii i Romero a Ventura (2013) či Peña-Ayala (2014b). Přehled několika novějších spíše vizualizačních nástrojů v kontextu analytiky učení pak nabízí opět Peña-Ayala (2018).

*Tabulka 4: Přehled vybraných analytických nástrojů a systémů a jejich stručný popis.*

<b>Název nástroje</b>	<b>Využívaná data</b>	<b>Stručný popis nástroje</b>	<b>Související publikace</b>
<i>AAT – Academic Analytics tool</i>	LMS/VLE	analýza chování studentů v rámci konkrétních výukových aktivit v kurzu	Graf, Ives, Rahman, & Ferri (2011)
<i>ASSISTments</i>	vlastní data	inteligentní tutorský systém	Heffernan & Heffernan (2014)
<i>AutoTutor</i>	vlastní data	inteligentní tutorský systém	D’Mello & Graesser (2012)
<i>CMA – Check My Activity</i>	LMS/VLE	vizualizace aktivity studentů v kurzu za účelem poskytnutí včasné zpětné vazby a srovnání se studijním pokrokem ostatních studentů v kurzu	Fritz (2011)
<i>Cognitive Tutor</i>	vlastní data	inteligentní tutorský systém	Koedinger & Corbett (2006)
<i>Coh-matrix</i>	vlastní data, texty studentů	analýza různých typů písemných prací studentů (eseje, seminární práce, příspěvky v diskuzních fórech apod.)	McNamara, Graesser, McCarthy, & Cai (2014)

<i>Course Signals</i>	LMS/VLE	predikce úspěšnosti a identifikace rizikových studentů	Arnold & Pistilli (2012)
<i>EIWM – E-learning Web Miner</i>	LMS/VLE	analýza chování studentů v rámci konkrétních výukových aktivit v kurzu	García-Saiz & Zorilla Pantaleón (2011)
<i>eLAT – exploratory Learning Analytics Toolkit</i>	LMS/VLE	vizualizace aktivity studentů v kurzu	Dyckhoff, Zielke, Bultmann, Chatti, & Schroeder (2012)
<i>GLASS</i>	LMS/VLE	vizualizace aktivity studentů v kurzu	Leony, Pardo, de la Fuente Valentín, de Castro, & Kloos (2012)
<i>Meerkat-ED</i>	LMS/VLE	analýza sociální sítě a vizualizace aktivity studentů v diskuzních fórech	Rabbany, ElAtia, Takaffoli, & Zaiane (2014)
<i>NAT – Network Awareness Tool</i>	vlastní data	vizualizační nástroj na podporu informálního učení v organizacích	Schreurs & De Laat (2012)
<i>OpenEssayist</i>	vlastní data, texty studentů	poskytování automatizované zpětné vazby studentům na jejich písemné práce	Whitelock et al. (2015)
<i>OU Analyse</i>	LMS/VLE, SIS	predikce úspěšnosti a identifikace rizikových studentů	Kužílek et al. (2015)
<i>SAM – Student Activity Meter</i>	LMS/VLE	vizualizace aktivity studentů za účelem podpory reflexe vlastního učení	Govaerts, Verbert, Duval, & Pardo (2012)
<i>SNAPP – Social Networks Adapting Pedagogical Practice</i>	LMS/VLE	analýza sociální sítě a vizualizace aktivity studentů v diskuzních fórech	Dawson, Bakharia, & Heathcote (2010)
<i>StepUp!</i>	LMS/VLE	vizualizace aktivity studentů za účelem podpory reflexe vlastního učení	Santos et al. (2013)

### 2.3.1. Analytické nástroje pro sumarizaci a vizualizaci dat

Velké množství pozornosti bylo v rámci analytiky učení (zvláště pak v jejích raných fázích) ale také v data miningu ve vzdělávání věnováno vývoji různých analytických či data miningových nástrojů pro sumarizaci a vizualizaci dat. V souvislosti s analytikou učení bývají tyto nástroje často označovány jako *learning analytics dashboards* a lze je charakterizovat tím, že využívají vizualizaci dat a relativně jednoduché statistiky či metriky (např. četnosti, průměry apod.) jakožto dvě hlavní analytické techniky. Primárním úkolem těchto nástrojů je sumarizování či vizualizace dat z různých online výukových prostředí za účelem poskytnutí důležitých informací odpovídajícím zúčastněným stranám, případně i s možností hlubšího prozkoumávání relevantních aspektů týkajících se učení v online prostředí (Klerkx, Verbert, & Duval, 2017). Zvláště v ranějších fázích rozvoje analytiky učení a data miningu ve vzdělávání bylo přitom nejvíce pozornosti věnováno takovým nástrojům, které byly určeny pedagogům, tutorům či administrátorům online kurzů, přičemž jim měly pomáhat analyzovat aktivitu studentů v kurzech (Romero & Ventura, 2010).

Postupem času se však zaměření jednotlivých *learning analytics dashboards* rozšiřovalo a v současnosti existuje řada nástrojů různých typů určených pro různé zúčastněné strany. Existují tak např. nástroje jako *CMA*, *SAM* či *StepUp!*, které jsou určené pro studenty a jež mají podporovat jejich reflexi vlastního procesu učení. Tyto nástroje se snaží poskytnout studentům informace např. o tom, kolik času tráví studiem různých materiálů, jak si vedou s ohledem na doporučený studijní plán či v porovnání s jinými studenty v kurzu apod. Na druhé straně jsou pak již zmiňované nástroje poskytující užitečné informace primárně učitelům, např.: *AAT*, *EIWM*, *eLAT* či *GLASS*. Jde o nástroje, které mají vyučujícím pomoci monitorovat chování studentů v online kurzech. Často prostřednictvím přehledné vizualizace aktivity studentů, příp. s možností srovnávání různých skupin studentů apod. Lze rovněž nalézt nástroje jako *Cohere*, *NAT* či *SNAPP* zaměřující se na využití metod analýzy sociálních sítí. V tomto kontextu za explicitní zmínku stojí relativně komplexní nástroj *Meerkat-ED*, který je určený zejména výzkumníkům a který může být poměrně snadno použit pro analýzu interakce studentů v online diskuzních fórech v LMS.

Zájem o problematiku *learning analytics dashboards* pokračuje až do současnosti a lze předpokládat, že tento výzkumný směr bude relevantní i v následujících letech. Zároveň je zde ale patrný určitý posun pozornosti jednak směrem ke komplexnějším či specifitěji zaměřeným analyticko-vizualizačním nástrojům, jednak směrem k výzkumu toho, jak se využívání určitého nástroje tohoto typu (ať již studenty či učiteli) promítá do samotného učení a výuky v online prostředí. Výzkumníci z oblasti analytiky učení přitom vykazují větší zájem spíše o otázky související s vizualizací, způsobem prezentace dat a širším kontextem využívání

těchto nástrojů v průběhu výuky (Klerkx, Verbert, & Duval, 2017; Wise & Vytasek, 2017). Naopak v oblasti data miningu ve vzdělávání je kladen větší důraz na zkoumání možností využití pokročilejších data miningových metod pro odhalování potenciálně zajímavých či užitečných informací v datech. Místo relativně jednoduchých statistik, vizualizací či reportů jsou tak využívány pokročilejší metody jako dolování asociačních pravidel, shlukování, klasifikace či dolování sekvencí (Romero & Ventura, 2010).

V data miningu ve vzdělávání je přitom věnována hlavní pozornost analytickým nástrojům určeným primárně pro učitele, tutorů a administrátory online kurzů či online vzdělávacích prostředí. Romero a Ventura (2010) dokonce v této souvislosti hovoří o samostatném specifickém směru výzkumu, který se zaměřuje na zkoumání možností využití data miningových metod pro automatizované poskytování podpůrné zpětné vazby učitelům či instruktorům v kurzu. Naopak v oblasti analytiky učení je větší pozornost věnována analyticko-vizualizačním nástrojům určeným pro studenty. Přitom jsou akcentovány především možnosti využití těchto nástrojů pro podporu seberegulace a seberegulovaného učení (*self-regulated learning*). K dispozici jsou již také systematické přehledové studie zaměřující se přímo *learning analytics dashboards* a mapující dosavadní výzkum v této oblasti (viz Bodily & Verbert, 2017; Matcha, Uzir, Gašević, & Pardo, 2019; Schwendimann et al., 2017).

### **2.3.2. Predikce úspěšnosti a identifikace rizikových studentů**

Za druhý významný směr výzkumů v oblasti analytiky učení a data miningu ve vzdělávání lze považovat snahu o predikci (ne)úspěchu studentů v jejich studiu, resp. identifikaci tzv. rizikových studentů<sup>64</sup>. Obecným úkolem predikce je odhad hodnoty určité proměnné. V tomto případě jde nejčastěji o proměnnou, která se týká úspěšnosti či výkonu studenta a jež je obvykle vyjádřena v podobě známky či určitého skóru. Má-li tato proměnná kategoričtý charakter, např. binární indikátor typu prospěl/neprospěl či známka na škále A až F, jde o predikci klasifikačního typu. Má-li naopak daná proměnná charakter čísla, například při predikci výkonu studenta v závěrečném testu, jedná se o prediktivní úlohu regresního typu, u které jsou používány jiné typy metod než v případě klasifikace (viz kapitola 2.2.1.3.1. *Prediktivní metody*).

V obou případech je přitom cílem správně predikovat úspěšnost či výkon studenta co možná nejdříve v průběhu kurzu či studia, aby tak bylo možné včas identifikovat ty studenty,

---

<sup>64</sup> Za „rizikové“ studenty jsou v tomto kontextu považováni ti studenti, kterým z jakéhokoli důvodu hrozí, že nebudou schopni dokončit konkrétní kurz či studium obecně.

kterým hrozí, že nebudou schopni úspěšně absolvovat kurz či dokončit své studium. Výsledky takové predikce totiž mohou být použity efektivnější intervenci a podpoře rizikových studentů (Clow, 2013). Při vývoji systémů zaměřených na tento typ predikce se pak často hovoří o tzv. systémech včasného varování (*early warning systems – EWS*), jejichž cílem je právě co možná nejvčasnější identifikace rizikových studentů. Tyto systémy jsou schopny na rizikové studenty upozornit vyučujícího, který se následně může rozhodnout, jakým způsobem bude danou situaci řešit. Zbývá dodat, že predikci úspěšnosti či výkonu studenta lze považovat za jedno z nejstarších a zároveň nejčastěji řešených témat v oblasti data miningu ve vzdělávání i v analytice učení (srov. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Peña-Ayala, 2018; Romero & Ventura, 2010).

Jedním z prvních a zároveň asi i nejčastěji zmiňovaným příkladem takového systému v odborné literatuře je nástroj *Course Signals* (viz tabulka 4), který byl vyvinut na *Purdue University*. Tento nástroj se zaměřuje na predikci (ne)úspěšnosti studentů v online kurzu, přičemž z pohledu uživatele se může zdát poměrně jednoduchým. Jeho základní funkcí je totiž pro každého studenta v kurzu zobrazit jednu z barev semaforu (červená, žlutá, zelená) na základě vypočtené pravděpodobnosti, že daný student úspěšně absolvuje kurz. Červená barva značí vysokou pravděpodobnost, že student kurz nedokončí, žlutá značí možné problémy či zvýšené riziko nedokončení a zelená barva je určena pro studenty, u kterých je predikována vysoká pravděpodobnost úspěšného dokončení kurzu. Za touto jednoduchou vizualizací se však skrývá poměrně komplexní výpočet kombinující čtyři různé složky: 1) dosavadní výkon studenta v kurzu, 2) množství dosavadní interakce v rámci LMS ve srovnání s ostatními účastníky kurzu, 3) předchozí studijní úspěšnost a 4) další (převážně demografické) charakteristiky studenta jako věk, trvalý pobyt apod. Dosavadní výsledky pak naznačují, že využití tohoto nástroje přispívá nejen k vyšší úspěšnosti studentů v jednotlivých kurzech, ale také ke snížení počtu studentů, kteří studium na univerzitě ukončí neúspěšně (Arnold & Pistilli, 2012)<sup>65</sup>.

Jak již bylo zmíněno, v případě predikce úspěšnosti a identifikace rizikových studentů jde o velmi významné téma v data miningu ve vzdělávání i v analytice učení. Lze se tak setkat s řadou studií věnujících se tomuto tématu, a to jak se studii staršího data (např. Lykourantzou, Giannoukos, Nikolopoulos, Mpardis, & Loumos, 2009; Macfadyen & Dawson, 2010), tak s výzkumy relativně aktuálními (např. Costa, Fonseca, Santana, de Araújo, & Rego,

---

<sup>65</sup> V případě nástroje *Course Signals* nejsou upozorňování pouze vyučující kurzu, nýbrž nástroj zároveň upozorňuje studenty, kterým posílá automaticky generovaný e-mail s varováním, že jim hrozí nedokončení kurzu. Studenti tak mohou po obdržení této informace okamžitě reagovat a podniknout kroky pro snížení rizika neúspěchu.

2017; Howard, Meehan, & Parnell, 2018; Marbouti, Diefes-Dux, & Madhavan, 2016). Jednotlivé studie se liší mimo jiné použitými prediktivními technikami (vedle lineární a logistické regrese bývají využívány např. podpůrné vektory, rozhodovací stromy, náhodný les, umělé neuronové sítě či naivní Bayesův klasifikátor), typy dat, které pro účely predikce využívají (nejčastěji data o aktivitě studentů v daném kurzu a data o předchozí úspěšnosti studentů ve studiu<sup>66</sup>), či samotnou proměnnou, kterou se snaží predikovat (jak již bylo naznačeno výše, může jít o známku za kurz, skóre v závěrečném testu apod.).

Za zmínku pak stojí rovněž to, že této problematice je věnována pozornost i v českém kontextu. Již relativně dlouho se této problematice věnuje několik českých výzkumníků, kteří se podíleli mimo jiné na vývoji nástroje *OU Analyse*, který byl vyvinut a je doposud rozvíjen v rámci *Knowledge Media Institute* na *Open University*. Tento nástroj kombinuje demografické údaje o studentech s daty o jejich aktivitě v LMS Moodle a pro identifikaci rizikových studentů využívá hlasování čtyř různých prediktivních modelů (Kužílek, Hlosta, Herrmannová, Zdráhal, & Wolff, 2015). V současnosti tento výzkum pokračuje i přímo v České republice na Českém vysokém učení technickém v Praze, kde Kužílek řeší juniorský projekt podpořený Grantovou agenturou České republiky (GAČR) s názvem *Predictive modeling of student performance using learning resources* (číslo projektu: 18-04150Y). Problematice se věnuje i několik výzkumníků na Fakultě informatiky Masarykovy univerzity (viz např. Bayer, Bydžovská, Géryk, Obšiač, & Popelínský, 2012; Bydžovská, 2016a; Bydžovská & Popelínský, 2013; Géryk & Popelínský, 2014).

### **2.3.3. Modelování studentů**

Dalším významným směrem výzkumu v oblasti analytiky učení a zvláště v data miningu ve vzdělávání je modelování studentů (*student modeling*). Jde o směr výzkumu, který může být chápán jako poměrně blízký výše zmiňované predikci úspěšnosti, což někteří autoři akcentují tím, že oba směry zařazují do jedné kategorie (např. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018). Na druhou stranu, jiní autoři (např. Papamitsiou & Economides, 2014; Romero & Ventura, 2010) tyto oblasti oddělují, jelikož i přes občasné používání relativně blízkých analytických metod a technik mají oba směry zásadně odlišné cíle a způsoby praktického uplatnění. Předně, jak naznačuje samotné označení obou směrů výzkumu, cílem predikce úspěšnosti je získat předpověď či odhad toho, zda student úspěšně dokončí kurz

---

<sup>66</sup> Najdou se ovšem i specificky zaměřené studie, které se záměrně snaží predikovat úspěšnost na základě omezené a specificky zaměřené sady dat. Např. Akçapınar, Hasnine, Majumdar, Flanagan a Ogata (2019) se zaměřují primárně na data týkající se toho, jak studenti využívají e-knihy. Saqr, Fors a Nouri (2018) věnují pozornost datům pocházejícím z online diskuzních fór apod.

případně celé studium. Cílem je tedy na základě současných (respektive v současnosti dostupných) dat odhadnout, jaká je pravděpodobnost, že daný student bude úspěšný na konci kurzu. Oproti tomu modelování studentů se nesnaží predikovat budoucí stav, nýbrž se snaží modelovat stav současný. To znamená, že místo odhadování, zda student za několik měsíců úspěšně dokončí kurz, se při modelování studentů snažíme zjistit například současnou úroveň znalostí studenta v rámci daného studovaného obsahu.

S výše uvedenými odlišnými cíli pak souvisí i odlišné způsoby využívání. Zatímco predikce úspěšnosti studentů se v praxi využívá téměř výhradně v kontextu zmiňovaných systémů včasného varování (EWS), modelování studentů je využíváno především pro účely personalizace či adaptace a najde tak praktické uplatnění především v inteligentních tuteurských systémech (např. tuteurské systémy *ASSISTments* a *Cognitive Tutor*, viz tabulka 4) či v různých typech adaptivních systémů (Baker & Inventado, 2014; Bakhshinategh, Zaiane, ELAtia, & Ipperciel, 2018; Peña-Ayala, 2014b).

Konkrétně lze modelování studentů chápat jako proces shromažďování relevantních informací s cílem odhadnout či odvodit určité aspekty či charakteristiky studenta a následně kvantitativně reprezentovat tyto aspekty či charakteristiky v podobně modelu, který může být využit pro automatizovanou adaptaci či personalizaci vzdělávacího obsahu či prostředí (srov. Chrysafiadi & Virvou, 2013; Peña-Ayala, 2014b; Sani, Bichi, & Ayuba, 2016). Mezi modelované aspekty či charakteristiky studentů patří například znalosti respektive úroveň znalostí, dovednosti, chyby a miskoncepce, učební strategie či preference, chování studenta (např. při plnění určitého úkolu), afektivní stavy a emoce či různé kognitivní a meta-kognitivní faktory (Bousbia & Belamri, 2014). Z těchto charakteristik se pozornost výzkumníků zaměřuje především na tři typy modelování studentů, které krátce představím a popíši v následujících podkapitolách. Konkrétně jde o modelování znalostí a dovedností studentů, modelování chování studentů a modelování emocí a afektivních stavů studentů (srov. Bakhshinategh, Zaiane, ELAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Peña-Ayala, 2014b).

### **2.3.3.1. Modelování znalostí a dovedností studentů**

Oblast modelování znalostí a dovedností lze považovat za nejtypičtějšího zástupce modelování studentů. To je dáno mimo jiné poměrně dlouhou historií této oblasti, která v určitých ohledech sahá daleko za oblast data miningu ve vzdělávání či analytiky učení a má výrazné styčné plochy s problematikou testování (zvláště pak počítačového adaptivního testování) v rámci psychologického výzkumu. V současnosti jde ale zároveň o jednu z velmi živých (a dnes již poměrně obsáhlých) oblastí výzkumu v kontextu data miningu ve

vzdělávání. To ostatně dokládá hned několik přehledových studií věnujících se tomuto tématu. Zvláštní pozornost si přitom zaslouží především studie Pelánka (2017), která se zaměřuje specificky na modelování znalostí a dovedností. Zmínit lze ale také několik dalších obecněji pojatých přehledů (např. Desmarais & Baker, 2012; Chrysafiadi & Virvou, 2013; Sani, Bichi, & Ayuba, 2016).

Modelování znalostí je přitom oproti ostatním typům modelování studentů asi nejužší spojeno s problematikou adaptivních systémů (viz níže kapitola 2.3.4. *Adaptivní a doporučovací systémy*) a inteligentních tutorských systémů jako jsou výše zmíněné *ASSISTments* (Heffernan & Heffernan, 2014) či *Cognitive Tutor* (Koedinger & Corbett, 2006), v rámci kterých nachází modelování znalostí hlavní praktické uplatnění. A ačkoli nejrůznější adaptivní a inteligentní tutorské systémy mohou stavět i na modelování chování či emocí a afektivních stavů studentů, model znalostí či dovedností studenta lze obecně považovat za jejich základní složku.

Za primární cíl modelování znalostí a dovedností můžeme spolu s Pelánkem (2017) považovat odhadování současného stavu znalostí či dovedností studentů spolu s predikcí jejich budoucího výkonu, a to na základě údajů o jejich dosavadních výkonech (tj. např. jak odpovídal na dosavadní otázky). Samotné modelování znalostí či dovedností je relativně komplexním procesem, do něhož vstupuje řada faktorů. Lze zmínit například znalostní doménu, ve které se pohybujeme (výuka jazyka, výuka programování apod.), typ znalosti či dovednosti, která má být modelována (např. učení se jednoduchým faktům versus učení se komplexním dovednostem), účel modelu, resp. způsob využití jeho výstupů (adaptace obsahu, vizualizace pokroku studenta v rámci dané znalostní domény atd.) či dostupná data, která mohou být využita pro účely modelování (srov. Pelánek, 2017). Všechny tyto faktory se přitom mohou odrážet v tom, jakou techniku či postup při modelování zvolíme. Pro účely základního přehledu je přitom užitečné provést obecné rozlišení na dva základní typy modelů, kterým zároveň odpovídají dvě různé formy adaptace a dva základní způsoby využití v rámci adaptivních respektive tutorovacích systémů (srov. Desmarais & Baker, 2012; Pelánek, 2017; Essa, 2016). Jedná se o vnitřní kognitivní model a vnější kognitivní model.<sup>67</sup>

---

<sup>67</sup> Toto či obdobné rozlišení je v literatuře činěno za pomoci různých pojmů (srov. Desmarais & Baker, 2012; Essa, 2016; Pelánek, 2017). Někteří autoři hovoří o vnitřní a vnější smyčce (*inner loop*, *outer loop*) v rámci modelování znalostí, jiní o mikroadaptaci a makroadaptaci (*micro-adaptation* a *macro-adaptation*, případně *microadaptivity* a *macroadaptivity*), další pak o přístupu založeném na analýze řešení problému (*problem solving and solution analysis*) a přístupu založeném na sekvencování kurikula (*curriculum sequencing*). V této práci se přidržuji rozlišení, které používá např. Essa (2016), který v návaznosti na vnitřní a vnější smyčku hovoří o vnitřních a vnějších kognitivních modelech (*inner and outer cognitive models*).



V případě **vnitřního kognitivního modelu** se zaměřujeme na postup studenta při řešení jednoho konkrétního problému či jedné úlohy. V tomto smyslu se tedy pohybujeme „uvnitř“ konkrétní úlohy a nevěnujeme se otázkám souvisejícím s přecházením mezi různými úlohami. Zároveň nás v kontextu vnitřních kognitivních modelů zajímají složitější problémy, jejichž řešení sestává z posloupnosti většího množství kroků. Tento typ modelů je tak využíván spíše v systémech, které se zaměřují na výuku komplexnějších znalostí či dovedností. Takové adaptivní systémy pak pro každou úlohu obsahují nejen informaci o jejím správném řešení, ale také o správné posloupnosti kroků, která k takovému řešení vede. Daný adaptivní systém (obvykle systém typu ITS) pak sleduje aktivitu studenta při plnění úlohy a dokáže mu v průběhu řešení problému poskytovat personalizovanou zpětnou vazbu (např. v podobě vysvětlení, proč je daný způsob řešení chybný, či v podobě nápovědy, jak správně postupovat při řešení problému). Z toho důvodu se v souvislosti s vnitřním kognitivním modelem hovoří o mikroadaptaci, kdy adaptace systému probíhá nikoli na úrovni úloh (a tudíž obsahu jako takového), nýbrž na úrovni zpětné vazby v rámci dané úlohy.

V případě **vnějšího kognitivního modelu** nás naopak až tak nezajímá, co se děje „uvnitř“ konkrétní úlohy, nýbrž věnujeme primární pozornost pořadí jednotlivých úloh, respektive tomu, jakou další úlohu dát studentovi k řešení. Adaptace tak v systémech tohoto typu probíhá na úrovni úloh, tj. každý uživatel dostává jiný obsah, jelikož buď dostává zcela jiné úlohy, anebo sice dostává z části stejné úlohy, ale ve svém vlastním pořadí. Proto se v tomto případě hovoří o makroadaptaci. Oproti vnitřním ve nějších kognitivních modelech využívány spíše úlohy jednoduchého charakteru (často v podobě výběru z možností), a vnější kognitivní modely jsou tak využívány především v adaptivních systémech zaměřujících se na výuku či procvičování faktických znalostí. Daný adaptivní systém pak v základní podobě funguje tak, že sleduje a vyhodnocuje, jak student odpovídal na předchozí úlohy (tj. zda odpověděl správně či špatně). Na základě toho odhaduje úroveň znalostí studenta a nabízí další úlohu odpovídající úrovně náročnosti.

V rámci obou těchto typů modelů se v současnosti používají různé způsoby či techniky modelování znalostí a dovedností. V případě vnitřních kognitivních modelů patří mezi relativně často využívané přístupy například tzv. modelování založené na omezeních (*constraint-based modeling*) či modely založené na pravidlech, které Pelánek (2017) nazývá *model tracing models*. Jak již název napovídá, modely založené na pravidlech sestávají ze sady pravidel typu „jestliže-pak“, které specifikují možné postupy při řešení dané úlohy. Naproti tomu modely založené na omezeních se nesnaží přesně vymežit možné způsoby řešení, nýbrž sestávají ze sady omezení, která musí studentovo řešení úlohy splnit. V případě vnějších kognitivních modelů pak patří mezi často zastoupené techniky např. modelování

označované jako *performance factor analysis* či jiné formy logistických modelů. Obecně je však zřejmě nejvíce pozornosti (alespoň v kontextu data miningu ve vzdělávání) věnováno technice označované jako *bayesian knowledge tracing* (BKT), kterou již v roce 1994 představili Corbett a Anderson (1994). Od jejího představení pak řada autorů pracovala na různých způsobech obohacení respektive rozšíření BKT. A to např. s ohledem na individualizaci BKT a zahrnutí parametrů specifických pro jednotlivé studenty, v souvislosti s integrací obtížnosti položek do modelu, či s ohledem na odhadování počáteční pravděpodobnosti, že student již má danou znalost či dovednost (srov. Desmarais & Baker, 2012; Pelánek, 2017).

### **2.3.3.2. Modelování chování studentů**

Druhou oblastí modelování studentů, která je významně zastoupena zvláště v kontextu data miningu ve vzdělávání, je modelování chování studentů. Oproti předchozí oblasti zaměřující se na znalosti a dovednosti studentů se tak výzkumníci v této oblasti věnují spíše tomu, jak se studenti chovají. Jde přitom primárně o chování související s učením<sup>68</sup>, čili se obvykle zkoumá chování studentů v určitém online vzdělávacím prostředí, případně i specificky v průběhu konkrétní výukové aktivity jako např. při vyplňování testu, při práci na zadaném úkolu, při práci ve skupině apod. Předmětem modelování se pak stávají různé typy či rysy chování studentů v závislosti na konkrétním typu výukové aktivity. Například při vyplňování testu může jít o identifikaci hádání či tipování odpovědí místo jejich korektního zodpovídání (tzv. *guessing behavior*). V případě práce na zadaném úkolu bývá věnována pozornost takovému chování, kdy student neví jak úkol splnit či jak dál postupovat, a tudíž vyžaduje či hledá nějakou pomoc (tzv. *help-seeking behavior*). U skupinové práce pak může být mapováno např. chování související s ochotou spolupracovat (*willingness to collaborate*) či mohou být modelovány různé způsoby participace jednotlivých studentů ve skupině (viz Baker & Inventado, 2014; Papamitsiou & Economides, 2014, 2016; Peña-Ayala, 2014b).

Napříč různými typy výukových aktivit je pak relativně častým zájmem výzkumníků modelování a identifikace takového chování, při kterém studenti aktivně plní zadaný úkol, soustředí se na něj a jsou jím zaujati, a kdy naopak zadaný úkol neplní a věnují se nějaké jiné aktivitě (tzv. *on-task* vs. *off-task behavior*, příp. *engagement* vs. *disengagement*). Pod takové „off-task“ chování pak mohou spadat situace od nesoustředěnosti či věnování se nesouvisející aktivitě, až po situace, při kterých student svým „off-task“ chováním ruší ostatní studenty

---

<sup>68</sup> Zvláště v angličtině též označované jako „učební chování“ (*learning behavior*). Odpovídajícím způsobem se pak hovoří též o modelování učebního chování (*learning behavior modeling*).

a narušuje tak výukovou aktivitu jako celek (srov. např. Baker, 2007; Baker & Gowda, 2010; Baker, Goldstein, & Heffernan, 2011).

A právě problematiku modelování a **detekce nežádoucího chování studentů** lze považovat za specifickou podoblast modelování chování studentů, které je v tomto kontextu věnována poměrně velká výzkumná pozornost. Někteří autoři (např. Bakhshinategh, Zaiane, ELAtia, & Ipperciel, 2018; Romero & Ventura, 2010) ji dokonce vyjmenovávají jako samostatný směr výzkumu, v případě Romera a Ventury (2010) dokonce až na stejné úrovni jako výše představené modelování studentů či predikci úspěšnosti. Ovšem s ohledem na to, že jde v případě těchto výzkumů stále o modelování chování studentů (totiž nežádoucího chování), považuji za vhodnější chápat tyto výzkumy jako součást obecnějšího směru výzkumů zaměřených na modelování studentů resp. jejich chování.

Jak již napovídá samotné označení „detekce nežádoucího chování studentů“, jde zde o modelování a identifikaci takových situací, při kterých v průběhu určité vzdělávací aktivity dochází k chování, které je v rozporu s cílem či smyslem dané výukové aktivity. Například v průběhu vyplňování online tesu může jít o již zmiňované hádání či tipování, případně o různé formy podvádění. V inteligentních tutorských systémech pak může jít např. o zneužívání pomoci resp. nápovědy, kdy student okamžitě či opakovaně požaduje poskytnutí nápovědy, aniž by se nejprve sám pokusil o vyřešení úlohy. Obecně se tyto jevy označují anglickým souslovím *gaming the system*, které lze přeložit jako „obcházení systému“<sup>69</sup>. Tímto pojmem se má na mysli takové chování, při kterém student záměrně využívá vlastností daného výukového systému k tomu, aby získal správné odpovědi či dosáhl úspěšného řešení úkolu, aniž by reálně znal správnou odpověď či uměl zadaný úkol vyřešit. Důvodem zájmu o modelování tohoto typu chování je především to, že souvisí s horším učením se prostřednictvím online výukových systémů typu ITS, čímž snižuje jejich potenciální přínos (Baker, 2007; Baker, Martin, & Rossi, 2017).

---

<sup>69</sup> Považuji za vhodné upozornit, že tento typ chování nelze zcela ztotožňovat s podváděním v běžném slova smyslu. Zatímco v případě podvádění jde obvykle o provádění něčeho, co je explicitně zakázané (tj. např. u závěrečného testu je zakázané opisovat, ale já přesto opisuji), v případě chování typu *gaming the system* jde o využívání takových vlastností systému, které nejsou explicitně zakázané (např. výše zmiňované zneužívání nápovědy).

### 2.3.3.3. Modelování emocí a afektivních stavů

Třetí významnou oblastí v rámci modelování studentů, která stojí za explicitní zmínku, je oblast zaměřující se na modelování emocí a afektivních stavů<sup>70</sup> studentů v průběhu učení. Výzkumníci v této oblasti vychází z přesvědčení, že emoce či obecně afektivní stavy se vesměs vždy určitým způsobem promítají do kognitivních procesů, a tudíž hrají významnou roli i v kontextu učení a vzdělávání. A ačkoli tyto afektivní stavy nemusí být daným subjektem v danou chvíli vědomě reflektovány, vždy nějakým způsobem ovlivňují poznávací proces a proces učení (D'Mello & Graesser, 2015; D'Mello, 2017). Hlavní pozornost je přitom věnována právě těm afektivním stavům a emocím, které studenti prožívají či mohou prožívat v průběhu učení. Pekrun a Stephens (2012) hovoří o tzv. akademických emocích (*academic emotions*), přičemž je dále rozdělují na emoce související s dosahováním úspěchu (*achievement emotions*), emoce související s tématem či obsahem učení (*topic emotions*), emoce související se sociálním kontextem učení (*social emotions*) a epistemické emoce (*epistemic emotions*) související s procesem poznávání<sup>71</sup>. D'Mello a Graesser (2015) místo o akademických emocích hovoří o tzv. na učení zaměřených afektivních stavech (*learning-centered affective states*), což lze ovšem chápat vesměs jako synonymní pojem. Konkrétně se přitom v realizovaných výzkumech z oblasti analytiky učení a data miningu ve vzdělávání setkáme především s následujícími afektivními či kognitivně-afektivními stavy (srov. Baker, D'Mello, Rodrigo, & Graesser, 2010; Bosch & D'Mello, 2017; D'Mello & Graesser, 2011; D'Mello, Craig, Witherspoon, McDaniel, & Graesser, 2008):

- frustrace (*frustration*),
- nuda (*boredom*),
- potěšení (*delight*),
- překvapení (*surprise*),
- úzkost (*anxiety*),
- vztek (*anger*),

---

<sup>70</sup> Zde je nutné upozornit na poměrně odlišné chápání tohoto pojmu v českém prostředí. Jak upozorňují např. Poláčková Šolcová a Trnka (2015), v českém odborném i laickém pojetí je pojem afekt obvykle chápán jako užší pojem, který je podřazený pojmu emoce. Emoce pak bývají děleny na afekty, nálady a vášně. V zahraničním kontextu je však situace jiná. Zde je obvykle pojem afekt (resp. afektivní stavy či jevy) považován za obecnější a emoce jsou pouze jedním z různých typů afektivních stavů. Z tohoto pojetí pak vychází i oblast modelování emocí a afektivních stavů (srov. např. D'Mello & Graesser, 2015; D'Mello, 2017), a tudíž se ho přidružuji i v této práci.

<sup>71</sup> Vzhledem ke zmiňované souvislosti s procesem poznávání se pro tuto kategorii používá rovněž označení kognitivně-afektivní stavy (*cognitive–affective states*), viz např. Baker, D'Mello, Rodrigo a Graesser (2010) či D'Mello a Graesser (2011).

- zaujetí či koncentrace (*engagement, flow, concentration*),
- zmatení (*confusion*),
- znechucení (*disgust*),
- zvědavost (*curiosity*).

Problematika modelování emocí a afektivních stavů je přitom akcentována spíše v rámci data miningu ve vzdělávání, kde čerpá především ze širších oblastí označovaných jako afektivní věda resp. vědy (*affective science*)<sup>72</sup> a zvláště z počítačového zpracování emocí (*affective computing*). V posledních letech však začíná být problematice emocí věnována pozornost i v kontextu analytiky učení, kde se hovoří o emoční analytice učení (*emotional learning analytics*), afektivní analytice učení (*affective learning analytics*) či jednoduše analytice emocí (srov. D'Mello, 2017; Williamson, 2017).

Podobně jako v ostatních oblastech modelování studentů se i u modelování afektivních stavů nachází uplatnění především v inteligentních tutorských systémech. Zde se pro účely modelování afektivních stavů využívají především logy či tzv. *click-stream data*, tj. taková data, která zachycují téměř veškerou interakci studenta s daným vzdělávacím systémem. Určitá část výzkumníků – ačkoli výrazně menší – se problematice detekce emocí a afektivních stavů věnuje i v souvislosti se systémy typu LMS či specificky v rámci kurzů typu MOOC (např. Aung & Myo, 2017; Wen, Yang, & Rosé, 2014; Yang, Kraut, & Rosé, 2016). Co se týče analyzovaných dat, jde v případě LMS a MOOC především o analýzu textových dat pocházejících z online diskuzních fór a využití analýzy sentimentu (*sentiment analysis*) jakožto metody analýzy těchto dat. Specifickou kategorií dat, které se rovněž využívají k detekci emocí a afektivních stavů, představují data zachycující určité tělesné signály (např. výraz tváře, postoj apod.). V případě tohoto typu dat se pak oblast modelování afektivních stavů do značné míry prolíná s oblastí označovanou jako multimodální analytika učení (viz kapitola 2.3.6.).

Co se týče praktické aplikace výsledků výzkumu z oblasti modelování emocí a afektivních stavů studentů, lze spolu s D'Mellem a Graesserem (2015) hovořit o specifické kategorii vzdělávacích technologií či systémů označovaných jako *affect-aware learning technologies* (AALT). Jde o takové vzdělávací technologie, které jsou schopny nějakým způsobem

---

<sup>72</sup> Označení *afektivní věda/y* je relativně nové. Jak zmiňují Poláčková Šolcová a Trnka (2015), mezinárodní Společnost pro afektivní vědu (*The Society for Affective Science*) byla založena teprve v roce 2013. Výzkum afektivních stavů samozřejmě existoval i dříve, teprve v posledních letech se však zdá, že sílí snaha výzkumníků zabývajících se afektivními stavy o to, aby tato oblast byla rozpoznávána a vnímána jako svébytná (podobně jako je tomu u kognitivní vědy resp. kognitivních věd).

identifikovat a zohledňovat afektivní stavy svých uživatelů. D'Mello a Graesser přitom rozlišují dva základní typy těchto technologií: reaktivní systémy a proaktivní systémy. Reaktivními systémy jsou myšleny takové systémy, které jsou schopny detekovat afektivní stavy studentů a následně na ně nějakým způsobem reagovat. Relativně častým úkolem je přitom identifikace „negativních“ afektivních stavů jako frustrace či nuda a následná reakce např. v podobě poskytnutí pomoci či vysvětlení vedoucího k řešení daného problému. Příkladem takového systému je upravená verze inteligentního tuteurského systému *AutoTutor* obohacená o detekci nudy, zmatení a frustrace (viz D'Mello & Graesser, 2012). Proaktivní systémy se pak místo reagování na emoce či afektivní stavy studentů snaží naopak určité emoce či afektivní stavy ve studentech vyvolávat. V tomto případě jde nejčastěji o využívání různých herních prvků za účelem zvyšování zaujetí (*engagement, flow*) či motivovanosti při plnění určitého úkolu (D'Mello & Graesser, 2015). Existují ovšem i pokusy se systémy snažícími se záměrně zvyšovat např. zmatení studentů (*confusion*). Ukazuje se totiž, že při využívání inteligentních tuteurských systémů může zmatení pozitivně souviset s učením a se studijními výsledky. Proto tyto proaktivní systémy v určitých momentech ve studentech strategicky navozují zmatení s cílem podpořit hlubší učení (D'Mello, Lehman, Pekrun, & Graesser, 2014).

#### **2.3.4. Adaptivní a doporučovací systémy**

Další oblastí výzkumu v rámci data miningu ve vzdělávání a z menší části i analytiky učení jsou adaptivní systémy (*adaptive systems*) a doporučovací systémy (*recommender systems*). Tato oblast přitom poměrně silně souvisí s modelováním studentů, jelikož pro tvorbu personalizovaných doporučení je obvykle potřeba pracovat s určitým modelem studenta či uživatele, pro kterého jsou daná doporučení určena. Přesto je oblast adaptivních či doporučovacích systémů řadou autorů (např. Bakhshinategh, Zaiane, ElAtia, & Ipperciel, 2018; Papamitsiou & Economides, 2014; Romero & Ventura, 2010) vnímána jako do značné míry svébytná a odlišná od modelování studentů. Za hlavní rozdíl lze přitom považovat odlišný primární cíl obou oblastí. Zatímco hlavním cílem modelování studentů je tvorba modelu, který pokud možno věrně zachycuje znalosti, chování či afektivní stavy studentů, v případě adaptivních a doporučovacích systémů je primárním cílem zajištění toho, aby studentům bylo poskytnuto relevantní doporučení, či aby se jim systém odpovídajícím způsobem přizpůsobil. Ačkoli se tedy obě oblasti do značné míry překrývají, zároveň se odlišují v tom, na co je kladen hlavní důraz (tvorba modelu versus zajištění personalizace/doporučení).

Zároveň je třeba provést základní rozlišení mezi adaptivními systémy a doporučovacími systémy. Přestože jsou oba typy systémů obdobné v tom, že pracují s personalizací či přizpůsobením se uživateli, je mezi nimi jeden zásadní rozdíl. Zatímco adaptivní výukové systémy (mezi které se běžně řadí i systémy typu ITS) obvykle uživateli přímo zobrazují personalizovaný obsah a uživatel tak vůbec nemá možnost, aby mu byl zobrazován obsah nepřizpůsobovaný, v případě doporučovacích systémů jde obvykle pouze o personalizované doporučení, kterým se student případně nemusí řídit. Příkladem adaptivního systému může být procvičovací systém sestávající ze sady různě obtížných úloh, který studentovi prezentuje takové úlohy, které nejlépe odpovídají jeho současné úrovni znalostí. Každému studentovi tedy budou úlohy prezentovány v jiném pořadí podle toho, jak odpovídal na předchozí úlohy. Pro studenta přitom neexistuje možnost postupovat úlohami v nepřizpůsobeném pořadí. Příkladem doporučovacího systému může být naopak systém, který studentovi doporučí kurzy k dalšímu studiu na základě toho, které kurzy student již absolvoval (či na základě jiných kritérií). Takové doporučení může studentovi pomoci se rozhodnout, je ale zcela na studentu samotném, jaký další kurz ke studiu si zvolí, a zda se vůbec bude řídit daným doporučením.

V rámci adaptivních systémů lze pak učinit základní rozlišení na adaptivní výukové systémy (*adaptive learning systems*) na jedné straně a na adaptivní testování (*adaptive testing*) častěji označované jako počítačové adaptivní testování (*computerized adaptive testing – CAT*) na straně druhé. A jak naznačuje již samotné označení obou typů adaptivních systémů, liší se primárně účelem, pro který jsou využívány. V prvním případě jde o podporu výuky resp. učení, zatímco v druhém případě jde spíše o testování resp. měření znalostí.

Jak upozorňují např. Jelínek, Květon a Vobořil (2011) či Žitný (2014), adaptivní testování jako takové má poměrně dlouhou historii. Výraznější rozvoj však začal až s rozšířením počítačů a výpočetních technologií. V současnosti lze oblast počítačového adaptivního testování považovat za jedno z velkých a moderních témat psychologického testování a testování obecně. V rámci data miningu ve vzdělávání a analytiky učení se výzkumníci obvykle zaměřují specificky na využití data miningových metod<sup>73</sup> pro účely adaptivního testování (např. Ivančević, Knežević, Pušić, & Luković, 2014) nebo na využití adaptivního testování pro formativní hodnocení (např. Baneres, Elena Rodríguez, Guerrero-Roldán, & Baró, 2016; Vie, Popineau, Bruillard, & Bourda, 2017). Přesto je větší pozornost v analytice učení a data miningu ve vzdělávání věnována adaptivním výukovým systémům než

---

<sup>73</sup> Na rozdíl od psychometrie a psychologického testování, kde se v souvislosti s adaptivním testováním využívá a rozvíjí především teorie odpovědi na položku (IRT).

adaptivnímu testování. Relativně významnou stopu v této oblasti zanechává i česká skupina *Adaptive Learning* fungující na Fakultě informatiky Masarykovy univerzity, která se zaměřuje mimo jiné právě na adaptivní procvičovací systémy (viz např. Papoušek, Stanislav, & Pelánek, 2016; Pelánek, 2016, 2017).

Co se týče doporučovacích systémů, pak vynecháme-li základní rozlišení na personalizované a nepersonalizované doporučování, které ve své disertační práci zmiňuje Bydžovská (2016b)<sup>74</sup>, lze doporučovací systémy rozdělit do několika základních kategorií na základě toho, jakým způsobem jsou doporučení tvořena. V data miningu ve vzdělávání a v analytice učení jsou přitom nejčastěji zmiňovány dvě základní kategorie (srov. např. Bydžovská, 2016b; Fazeli, Drachler, Brouns, & Sloep, 2014; Manouselis, Drachler, Verbert, & Duval, 2013):

- **Na obsahu založené doporučování** (*content-based recommendation*) spočívá v tom, že je uživateli doporučován takový obsah, který je v nějakém ohledu podobný tomu, který uživatel preferoval v minulosti. V případě systému doporučujícího kurzy by tak mohlo jít o doporučování takových kurzů, které jsou tematicky podobné těm, které student již absolvoval. Systémy tohoto typu jsou tak obvykle tvořeny třemi částmi (viz Bydžovská, 2016b): První část zajišťuje porozumění obsahu potenciálních položek k doporučení. Budeme-li tedy pokračovat ve výše nastíněném příkladu, pak v této části jde o to, aby doporučovací systém věděl, jakému tématu se věnují všechny kurzy, které mohou být uživatelům potenciálně nabízeny. Druhá část vytváří modely či profily jednotlivých uživatelů. To znamená, že o každém uživateli sbírá informace o tom, která témata ho zajímají. Třetí část pak tvoří samotná doporučení na základě porovnání profilu uživatele s popisem nabízených položek. Dochází tedy ke srovnání tematického zájmu konkrétního uživatele s tematickou nabídkou kurzů, přičemž se hledají nejlepší shody.
- **Kolaborativní doporučování** (*collaborative recommendation*) označované také jako kolaborativní filtrování (*collaborative filtering*) funguje tak, že je uživateli doporučován takový obsah, který je preferován uživateli, jež mu jsou v nějakém ohledu podobní. V případě systému doporučujícího kurzy by tak určitému studentovi byly doporučovány např. takové kurzy, které jsou pozitivně hodnoceny studenty, jež mají obdobné zájmy jako student, pro kterého je doporučení tvořeno. Romero a Ventura

---

<sup>74</sup> Za nepersonalizované doporučovací systémy lze považovat jednoduché systémy, které doporučují stejné položky všem uživatelům. Příkladem by mohl být systém, který by všem uživatelům doporučoval např. nejlépe hodnocené kurzy či nejnovější kurzy.



(2010) zmiňují několik způsobů využití kolaborativního filtrování ve vzdělávání, například kontextově-relevantní doporučování vhodných učebních objektů, doporučování odkazů na rozšiřující studijní materiály či doporučování obsahu, který by se měl student naučit před tím, než se přesune ke studiu další části kurzu.

Vedle dvou výše představených typů pak někteří autoři zmiňují ještě další možné typy doporučovacích systémů. Např. Manouselis et al. (2013) zmiňují doporučování na základě demografických údajů (*demographic recommendation*), doporučení na základě užítka či užitečnosti (*utility-based recommendation*) a doporučení na základě znalostí (*knowledge-based recommendation*). Bydžovská (2016b) pak doplňuje ještě hybridní doporučovací systémy, které spočívají v kombinaci několika z výše uvedených metod.

### **2.3.5. Sociální analytika učení**

Sociální analytiku učení (*social learning analytics*)<sup>75</sup> lze chápat jako specifickou podoblast analytiky učení, která se do určité míry vymezuje vůči přístupům a výzkumům, které se orientují především na jedince (tj. zvláště směry zaměřující se na predikci úspěšnosti, identifikaci rizikových studentů či modelování studentů). Za původní proponenty tohoto směru výzkumu lze považovat Buckingham Shuma a Fergusonovou (srov. Buckingham Shum & Ferguson, 2012; Ferguson & Buckingham Shum, 2012), pro které je sociální analytika učení specifickou podmnožinou analytiky učení v tom smyslu, že vychází z pojetí učení jako sociálního procesu. Podle těchto autorů nemůže být učení dostatečně pochopeno, dokud se budeme soustředit pouze na studenty jakožto jednotlivce a nebudeme brát zřetel na důležité sociální aspekty jako interakce, spolupráce, skupinové procesy apod. Siemens (2012) se přidává k těmto hlasům, když zdůrazňuje nutnost přesunu pozornosti výzkumníků od pouhé identifikace rizikových studentů směrem k jiným přístupům a metodám. Identifikace rizikových studentů sice dle Siemense je a zůstane důležitým tématem na poli analytiky učení, zároveň však podle něj tvoří identifikování rizikových studentů pouze relativně malou část toho, čím vším může analytika přispět ke zlepšení vzdělání (Siemens, 2012).

Hlavní charakteristikou sociální analytiky učení, kterou se dle uvedených autorů odlišuje od ostatních výzkumných směrů v této oblasti, jsou pak především analytické metody a techniky, pomocí kterých se snaží zachycovat sociální aspekty učení. Fergusonová a Buckingham Shum (2012) zmiňují v souvislosti se sociální analytikou učení pět hlavních

---

<sup>75</sup> Přikláním se k používání jednotného překladu v podobě „sociální analytika učení“, přestože anglické sousloví „social learning analytics“ by v některých kontextech zřejmě bylo možné chápat a do češtiny překládat rovněž jako „analytika sociálního učení“.

skupin metod či metodologických okruhů (přestože si nedělají nároky na úplnost tohoto výčtu):

1. Analytika sociálních sítí (*social network analytics*).
2. Analytika diskurzu (*discourse analytics*).
3. Analytika obsahu (*content analytics*).
4. Analytika dispozic (*disposition analytics*).
5. Analytika kontextu (*context analytics*).

Stěžejní roli v dosavadních výzkumech spadajících pod sociální analytiku učení však hraje využívání metod analýzy sociálních sítí (SNA) a automatizovaného zpracování přirozeného jazyka (NLP). Tato dominance se následně odrazila i v obsahové náplni stěžejní publikace *Handbook of Learning Analytics* (Lang, Siemens, Wise, & Gašević, 2017), která vyšla o několik let později od publikování výše uvedené pětice metod, a ve které se v sekci technik a přístupů analytiky učení objevují jako samostatné kapitoly pouze analytika diskurzu (*discourse analytics*) a analytika obsahu (*content analytics*), jež jsou obě do značné míry založené na automatizované analýze textových dat.<sup>76</sup> Mimo tyto dvě kapitoly se pak v této přehledové publikaci objevuje rovněž kapitola s názvem *Natural Language Processing and Learning Analytics* (McNamara et al., 2017), což dále podtrhuje důraz na metody zpracování přirozeného jazyka. Ostatně výzkumníci pohybující se spíše v oblasti data miningu ve vzdělávání (např. Baker & Inventado, 2014) často považují právě důraz na metody automatizované analýzy textových dat či metody analýzy diskurzu za jednu z hlavních charakteristik, ve kterých se analytika učení odlišuje od data miningu ve vzdělávání.

S ohledem na výše uvedené se v následujících podkapitolách zaměřuji podrobněji na tři nejčastěji uváděné a v rámci sociální analytiky učení nejvíce zastoupené oblasti: analytiku sociálních sítí (kterou chápu jako aplikaci analýzy sociálních sítí v kontextu analytiky učení), analytiku obsahu a analytiku diskurzu.

### **2.3.5.1. Analytika sociálních sítí**

Jak jsem již naznačil výše, označení analytika sociálních sítí (*social network analytics*) se od jeho zavedení v roce 2012 (viz Ferguson & Buckingham Shum, 2012) příliš nerozšířilo. A to

---

<sup>76</sup> Chybějící kapitolu, která by se věnovala specificky analytice sociálních sítí (*social network analytics*), lze vysvětlit zřejmě především tím, že se toto označení v odborné komunitě příliš neujalo. Důvodem je nejspíš přílišná podobnost označení *social network analytics* s již existujícím a dlouhodobě používaným *social network analysis*. Označení *social network analysis* přitom není běžně chápáno jakožto označení specifického metodologického okruhu v rámci sociální analytiky učení, nýbrž jde o označení pro širokou oblast analytických metod používaných i v řadě dalších disciplín (viz kapitola 2.2.1.3.5. *Analýza sociálních sítí*).

zřejmě především kvůli tomu, že se jím odkazovalo na využití metody analýzy sociálních sítí (SNA) v kontextu analytiky učení. Pojem analýza sociálních sítí přitom byl již tou dobou mnohem více rozšířen, takže se nelze příliš divit, že se většina výzkumníků přiklání spíše k využívání tohoto pojmu. Proto i v této kapitole používám primárně pojem analýzy sociálních sítí místo analytika sociálních sítí<sup>77</sup>.

Analýzu sociálních sítí (SNA) můžeme chápat jako soubor metod a technik sloužících k průzkumu různých typů sociálních sítí (viz kapitola 2.2.1.3.5. *Analýza sociálních sítí*). Za sociální síť lze přitom považovat nejen online sociální síť jako Facebook či Twitter, ale také např. sociální vztahy mezi studenty ve třídě či diskuzi studentů v online výukovém prostředí apod. Analýza sociálních sítí přitom bývá využívána jak v kvantitativně, tak i v kvalitativně orientovaných výzkumech, přestože výrazně silnější zastoupení má ve výzkumech kvantitativního charakteru.

V současnosti je pak analýza sociálních sítí natolik obsáhlým souborem metod, že ji lze jen stěží představit na ploše několika odstavců. Zmíním proto jen tři základní body. Vedle využití SNA pro analýzu určité sítě či skupiny osob lze tyto metody využít rovněž v případech, kdy je pozornost zaměřována na konkrétní osobu. V těchto případech se pak obvykle hovoří o osobních či egocentrických (*egocentric*) sítích resp. egocentrické analýze sociálních sítí. Mimo mapování sociální sítě v určitém okamžiku (tj. ve statické podobě) nabízí analýza sociálních sítí rovněž metody a techniky věnující se dynamickým sítím (*dynamic social network*), tj. takovým sítím, které se v čase mění. V neposlední řadě se pak techniky analýzy sociálních sítí využívají i při analýze textových dat a v rámci dolování textů. Jde například o síť spoluvýskytů slov v analyzovaných textech (*term co-occurrence networks*). V kontextu systémů typu LMS lze taková data extrahovat a následně analyzovat například pomocí výše zmiňovaného nástroje *Meerkat-ED* (Rabbany, ElAtia, Takaffoli, & Zaiane, 2014). Nutno zároveň dodat, že v takovém případě se už dostáváme spíše do oblasti analytiky obsahu či analytiky diskurzu, kde jsou rovněž využívány metody a techniky analýzy sociálních sítí.

Co se pak týče výzkumů využívajících metod analýzy sociálních sítí, lze uvést například případovou studii Brookse, Greera a Gutwina (2014), kteří použili SNA k mapování aktivity studentů v online diskuzních fórech. Gašević, Zouaq a Janzen (2013) pak hledali s pomocí SNA vztah mezi sociálním kapitálem studentů a jejich studijními výsledky, zatímco Joksimović et al. (2016) se zaměřili na souvislost mezi mírou centrality studentů v síti a jejich

---

<sup>77</sup> Pokud bychom chtěli mezi oběma pojmy striktně odlišovat, pak pojem „analýza sociálních sítí“ bude označovat specifickou metodu resp. skupinu metod, zatímco „analytika sociálních sítí“ bude sloužit k označení dílčí oblasti analytiky učení, která se zaměřuje právě na využití metod analýzy sociálních sítí.

studijními výsledky. Jiný zajímavý příspěvek k metodologii SNA přidávají Kim a Lee (2012), kteří zkoumají možnosti multidimenzionálního přístupu pro analýzu vztahů mezi jednotlivci v průběhu online interakce. Hecking, Ziebarth a Hoppe (2014) se pak snaží s pomocí SNA identifikovat různé způsoby využívání studijních materiálů v online kurzech. Za zmínku rovněž stojí práce de Laata a Schreurse (2013), kteří SNA spolu s dalšími metodami sociální analytiky učení využili v kontextu neformálního profesního rozvoje. Obdobným směrem se vydávají i Abu Khouza a Atif (2018), kteří se věnují analýze sociálních sítí při výzkumu kariérního rozvoje.

Za specifický způsob využití SNA, který již směřuje mimo oblast analytiky učení, lze pak považovat studii, ve které jsem analyzoval sociální sítě publikujících autorů, výzkumných institucí a odborných časopisů v pedagogických vědách v České republice (Juhaňák, 2017).

### **2.3.5.2. Analytika obsahu**

Analytika obsahu či obsahová analytika (*content analytics*) může být chápána jako zastřešující termín pro sadu metod a metodologických přístupů v rámci analytiky učení, které se zaměřují specificky na analýzu učebního obsahu (*learning content*). Pokud bychom chtěli dát přesnější definici analytiky obsahu, můžeme se místo staršího vymezení (viz Buckingham Shum & Ferguson, 2012; Ferguson & Buckingham Shum, 2012) přiklonit spíše k novějšímu a širšímu pojetí Kovanoviće et al. (2017, s. 76), kteří obsahovou analytiku chápou jako:

*Automatizované metody zkoumání, evaluace, indexování, filtrování, doporučování a vizualizace různých forem digitálního učebního obsahu, bez ohledu na jeho producenta (např. instruktor, student) s cílem přispět k porozumění učebním aktivitám a ke zlepšení vzdělávací praxe a výzkumu.*

Oproti zaměření pozornosti na studenta a na jeho znalosti, chování či afektivní stavy, se analytika obsahu zaměřuje především na analýzu různých učebních zdrojů a produktů učení. Učebním zdrojem (*learning resource*) se myslí především nejrozličnější online studijní materiály, elektronické učebnice apod., zatímco učebními produkty (*products of learning*) jsou především odevzdávané úkoly studentů, seminární práce, zprávy v diskuzních fórech apod. A ačkoli učební zdroje i produkty učení mohou existovat v různých formátech (audio, video, text, animace apod.), dosavadní pozornost výzkumníků v této oblasti se zaměřuje především na textové učební zdroje a produkty.

V rámci analytiky obsahu učebních zdrojů lze přitom spolu s Kovanovičem et al. (2017) rozlišit tři základní dílčí oblasti, kterým výzkumníci věnují pozornost. V prvním případě má obsahová analytika velmi blízko k doporučovacím systémům (viz předchozí kapitola 2.3.4. *Adaptivní a doporučovací systémy*), kdy je cílem studentům na základě analýzy obsahu

učebních zdrojů automaticky nabízet a doporučovat relevantní učební materiály. Druhým tématem obsahové analytiky učebních zdrojů je automatizovaná organizace či klasifikace výukových materiálů či obecně učebních objektů (*learning objects*). Zde se využívají metody jako automatická extrakce klíčových slov, kolaborativní tagování, shlukování či automatizované anotování. Hlavním cílem je přitom automatizovaně získat metadata o učebních zdrojích, pomocí kterých by pak bylo možné je následně vhodným způsobem uspořádat a popsat, aby se v nich studenti mohli efektivně orientovat. Se stále větším rozšířením multimediálních výukových materiálů se v obsahové analytice postupně začíná věnovat pozornost i těmto typům učebních zdrojů. Např. Brooks, Johnston, Thompson a Greer (2013) se zaměřují na techniky automatické detekce a kategorizace důležitých pasáží ve videozáznamech přednášek, aby tak studentům umožnili lépe se v těchto videozáznamech pohybovat a využívat je pro své učení. Třetí důležitá oblast analytiky obsahu učebních zdrojů se zaměřuje na hodnocení kvality či náročnosti obsahu výukových materiálů. V tomto kontextu byl využit např. nástroj *Coh-matrix* (McNamara, Graesser, McCarthy & Cai 2014), který se jinak používá především pro analýzu a hodnocení studentských písemných prací.

V rámci analytiky obsahu učebních produktů je stěžejní oblastí zájmu využití obsahové analýzy pro automatizované poskytování zpětné vazby na písemné práce studentů a automatizované hodnocení písemných prací studentů (*automated essay scoring – AES*). Pro tyto účely je využíván např. již zmiňovaný nástroj *Coh-matrix* (McNamara, Graesser, McCarthy & Cai 2014), který za využití techniky latentní sémantické analýzy (*latent semantic analysis – LSA*) umožňuje hodnotit např. soudržnost (koherenci) či informativnost analyzovaných textů studentů. Jiným příkladem nástroje obdobného typu je *OpenEssayist* (Whitelock et al., 2015), který se zaměřuje spíše na poskytování automatizované zpětné vazby studentům v průběhu tvorby jejich písemných prací. K tomu využívá mimo jiné vizualizaci v podobě sítí spoluvýskytů slov, které byly zmíněné výše.

### **2.3.5.3. Analytika diskurzu**

Analytika diskurzu podobně jako analytika obsahu poměrně výrazně čerpá z technik a metod zpracování přirozeného jazyka. Díky tomu také oblast analytiky diskurzu sdílí mnohé charakteristiky s výše popsanou analytikou obsahu. Určitým rozdílem je však to, že v rámci analytiky diskurzu je věnována hlavní pozornost souvislostem mezi interakcí a komunikací studentů v přirozeném jazyce a jejich učení. Často se proto v analytice diskurzu věnuje pozornost právě takovým textovým datům, která zachycují určitý dialog či nějakou formu interakce mezi studenty (Ferguson & Buckingham Shum, 2012). Nejčastěji jde o analýzy komunikace studentů v online diskuzních fórech, chatech a jiných nástrojích na synchronní

či asynchronní online komunikaci. Může jít ale také o analýzy obsahu výukových blogů či wiki nástrojů, jejichž součástí obvykle bývají nástroje na komentování či diskutování. Někteří výzkumníci rovněž věnují pozornost analýzám a automatickému zpracování odpovědí studentů na (kratší) otevřené otázky (Rosé, 2017).

Za typický příklad využití analytiky diskurzu lze považovat analýzu komunikace v diskuzních fórech v rámci masových otevřených online kurzů (MOOC). Tyto kurzy totiž běžně obsahují tisíce až desetitisíce studentů, a tudíž v nich vzniká obrovské množství diskuzních příspěvků, se kterými vyučující či tutoři kurzu nemohou pracovat běžným způsobem (tzn. číst všechny příspěvky a odpovídat na ně). Výzkumníci v oblasti analytiky diskurzu se tak věnují různým možnostem analýz těchto rozsáhlých diskuzí, jejichž výstupy by mohly vyučujícím a tutorům poskytnout lepší vhled do dění v diskuzních fórech. Mezi nejčastější typy analýz přitom patří analýza sentimentu umožňující identifikovat pozitivní a negativní emoce vyjadřované v diskuzních příspěvcích. Časté je rovněž tzv. modelování tématu (*topic modelling*) resp. identifikace či objevování tématu (*topic discovery*), které umožňují automaticky identifikovat hlavní témata vyskytující se v diskuzích studentů v online kurzu. Na základě těchto technik tak mohou být automatizovaně identifikována hlavní témata, problémy či otázky, které studenti v online diskuzním fóru zmiňují a na jejichž řešení či zodpovězení se lektori a tutoři online kurzu mohou zaměřit. Příkladem může být systém *FAQtor*, na jehož vývoji pracují Bihani, Ullman a Paepcke (2018). Ten je schopen analyzovat obsah diskuzních příspěvků ve fóru a následně automaticky generovat seznam tzv. často kladených dotazů (*frequently asked question – FAQ*).

### **2.3.6. Multimodální analytika učení**

Podobně jako se výše představená oblast sociální analytiky učení do jisté míry vymezovala vůči jiným přístupům v rámci analytiky učení a data miningu ve vzdělávání, tak i oblast multimodální analytiky učení (*multimodal learning analytics*) vzniká v určitém ohledu jako vymezení se vůči převažující výzkumné praxi analytiky učení a data miningu ve vzdělávání. Jak shrnuje Ochoa (2017) tyto oblasti již od svého vzniku zaměřovaly pozornost především na studium aktivit studentů v různých typech online výukových systémů jako např. LMS či ITS. Radikálně méně pozornosti však bylo v těchto oblastech věnováno jiným prostředím a kontextům, kde dochází k učení (semináře, přednášky, studijní skupiny apod.). Toto nerovnoměrné rozložení pozornosti samozřejmě pramení z faktu, že online výuková prostředí obvykle automaticky sbírají velká množství relativně podrobných dat a činí tak tato data pro výzkumníky v oblasti data miningu ve vzdělávání a analytiky učení poměrně snadno dostupná. Naopak v tradičních či „off-line“ učebních kontextech, tj. tam, kde se aktivita

studentů neodehrává skrze počítač, není aktivita studentů nijak automatizovaně zaznamenávána, což klade výrazně větší nároky na sběr dat.

Ochoa (2017) ovšem zároveň upozorňuje, že tento sklon výzkumníků k využívání primárně dat z online výukových systémů může produkovat tzv. efekt pouličního osvětlení (*streetlight effect*), resp. princip opilcova hledání (*the principle of the drunkard's search*). Tato metaforická označení se používají v souvislosti se zkreslením (*bias*), které vzniká díky tomu, že výzkumníci při svém výzkumu častěji zaměřují pozornost tam, kde vidí větší šanci získání pozitivních výsledků nebo tam, kde lze výzkum (např. pozorování, experiment apod.) provádět snadněji (Freedman, 2010).<sup>78</sup> Multimodální analytika učení se snaží reagovat právě na tento potenciální problém a vymezuje se vůči těm přístupům, které se upínají pouze k analýze dat z online výukových systémů. Tím totiž takové přístupy ignorují řadu dalších informací, jež však mohou být zcela zásadní i pro vysvětlování chování studentů právě v online výukových systémech (příkladem mohou být situace, kdy se studenti tváří zmateně či zívají nudou při řešení úkolu v online výukovém systému).

Hlavním cílem multimodální analytiky učení je tedy právě ona kombinace různých zdrojů, dat či modalit, které mohou poskytovat důležité informace pro porozumění učení v daném kontextu (Ochoa, 2017). Pokud bychom měli podat konkrétní definici multimodální analytiky učení, pak lze využít vymezení, které nabízí Blickstein a Worsley (2016, s. 233) pojímající multimodální analytiku učení jako:

*(...) soubor [analytických] technik zaměřujících se na využití vícečetných zdrojů dat (video, logy, text, artefakty, audio, gesta, biosenzory) za účelem zkoumání učení v realistických, ekologicky validních, sociálních výukových prostředcích kombinujících různé druhy médií.*

Pojem multimodality přitom vychází primárně z teorie komunikace, kde odkazuje k tomu, že komunikace a výměna informací může probíhat v různých modech (textový, řečový, vizuální apod.). Jak ale upozorňuje Jewittová (2012), tento pojem přejali i výzkumníci v pedagogice, zvláště pak v kontextu e-learningu a technologií ve vzdělávání, jelikož multimodalita je charakteristická i pro samotné učení (student si může číst knihu, poslouchat přednášku, sledovat výukové video, dělat cvičení v LMS atd.). Multimodální analytika učení

---

<sup>78</sup> Označení „princip opilcova hledání“ souvisí se známým vtípem, který se běžně využívá k ilustraci tohoto typu zkreslení: Pozdě v noci narazí policista na opilého muže, který pod pouliční lampu něco hledá. Opilý muž policistovi řekne, že hledá svoji peněženku. Když se policista zeptá, jestli si je muž jistý, že ji ztratil právě tam, opilec mu odpoví, že ji nejspíš ztratil na druhé straně ulice. Zmatený policista se zeptá: „Proč tedy peněženku hledáte zde?“, načež opilec vysvětluje: „Protože tady jde lépe vidět.“ (viz Freedman, 2010)

pak usiluje o rozvoj metod a technik pro sběr, analýzu a kombinaci dat o učení probíhajícím prostřednictvím různorodých modů.

Na základě analýzy dosavadních empirických studií v oblasti multimodální analytiky učení lze říci, že výzkumníci doposud věnují pozornost především následujícím pěti modalitám resp. datům, které je zachycují: audio, video, biofyzilogické údaje, sledování pohybu očí (*eye tracking*) a logy zaznamenávající interakci v online výukových systémech (Worsley, 2018). Mimo tyto nejčastěji řešené modality však výzkumníci v této oblasti věnují pozornost i dalším modům. S oporou o přehledové publikace, které nabízí např. Blikstein a Worsley (2016) či Ochoa (2017), lze výzkum v oblasti multimodální analytiky učení shrnout do následujících kategorií:

- **Analýza textů (*text analysis*).** V tomto bodě se multimodální analytika učení vesměs překrývá s analytikou obsahu či s analytikou diskurzu. A podobně jako v uvedených oblastech jsou i v kontextu analýzy textů používané především metody a techniky z oblastí jako dolování textu a zpracování přirozeného jazyka. V multimodální analytice učení však analýza textů není dominantním prvkem, jako například u analýzy obsahu. Roli zde samozřejmě opět sehrává to, že textová data jsou ve vzdělávání (ať již online či off-line) rozšířena velmi výrazně, a zároveň je jejich sběr po technické stránce relativně jednoduchý.
- **Analýza promluv (*speech analysis*).** Jde asi o nejčastěji zastoupenou kategorii v kontextu multimodální analytiky učení. Analýza promluv zároveň z části sdílí cíle a metody analýzy textů. Audiozáznamy promluv se totiž obvykle používají jedním ze dvou základních způsobů. V prvním případě je pozornost věnována tomu, co je v rámci promluvy sdělováno. Zde je pak audiozáznam využit k získání textového přepisu promluvy, obvykle za využití technik automatizovaného rozpoznávání řeči (*speech recognition*), a následně se s datovým materiálem pracuje obdobně jako v rámci analýzy textů. Druhý přístup k analýze promluv se pak zaměřuje především na to, jak bylo něco řečeno, tzn. na různé prozodické vlastnosti řeči jako intonace, důraz, tempo, rytmus apod. Z těchto charakteristik lze pak získávat doplňující informace o záměrech či interních stavech mluvčích (např. nervozita apod.).
- **Analýza rukopisu a skic (*handwriting analysis, sketch analysis*).** Třetí oblast, která je do značné míry blízká předchozím dvěma a tím zprostředkovaně i analytice obsahu, je analýza rukopisu resp. písemných záznamů, případně analýza skic, kreseb apod. Podobně jako v případě promluvy pak může být věnována pozornost jednak tomu, co je psáno či kresleno, jednak také tomu, jakým způsobem



(rychlost psaní, tempo, tlak na pero apod.). Sběr tohoto typu dat se stal samozřejmě mnohem snadnější poté, co se staly běžnými technologie jako digitální pero či tablet se stylusem.

- **Analýza pohledu a sledování pohybu očí (*gaze analysis, eye tracking*).** Monitorování toho, kam se studenti dívají, může poskytovat především informaci o tom, čemu právě věnují pozornost. Technologii pro sledování pohybu očí je v současnosti věnována značná pozornost i daleko za rámec pedagogických věd. Přestože jsou k dispozici různé typy přístrojů od těch, které využívají statické monitory, až po ty, které pracují s mobilními brýlemi, výraznější využívání těchto přístrojů v přirozeném učebním kontextu je stále poměrně problematické (ať již z důvodu stále relativně velkých finančních nákladů, nebo z důvodu jejich možné rušivosti v přirozeném prostředí). Z těchto důvodů se pro analýzu pohledu v multimodální analytice učení poměrně často využívá i videozáznam pomocí běžné kamery (či sady kamer) zachycující hlavu, resp. obličej studentů. Za využití kombinace metod pro zpracování obrazu, spolu s informací o relativní poloze studentů a kamery, lze pak s určitou přesností usuzovat na směr pohledu studentů a zjišťovat tak např. to, zda věnují vizuální pozornost vyučujícímu, resp. zda jej mají v zorném poli (viz Raca & Dillenbourg, 2013).
- **Řeč těla (*mimika, gestika, posturika atd.*).** Další oblast, které je v kontextu multimodální analytiky učení věnována pozornost, souvisí s tzv. řečí těla, tj. sledováním výrazů tváře, gest, postoje, pohybu a držení těla apod. Podobně jako v případě eye trackingu lze i v tomto případě využít řadu různých přístrojů či senzorů, které s pomocí akcelerometru dokáží poměrně přesně sledovat pozici a pohyb jednotlivých částí těla, ke kterým jsou připojeny. Ovšem vzhledem k jejich invazivnosti bývá i zde často využíván spíše běžný videozáznam a jeho následná analýza. Např. Raca, Tormey a Dillenbourg (2014) využili videozáznam třídy zachycující pohyby horní poloviny těla studentů k měření jejich pozornosti. Zajímavým příkladem výzkumu kombinujícího data ze senzorů pohybu s videozáznamem je práce Echeverría et al. (2014), kteří využili data ze zařízení Kinect spolu s videozáznamem horní poloviny těla pro predikci úrovně prezentačních dovedností studentů.
- **Sledování biofyzilogických ukazatelů.** Do této kategorie spadá využívání jakýchkoli přístrojů, které umožňují měřit a monitorovat nejrůznější biofyzilogické či neurofyzilogické procesy v lidském těle. Blikstein a Worsley (2016) uvádí jako nejběžnější příklady v kontextu pedagogického výzkumu měření

srdečního tepu, měření dilatace zornic, měření elektrodermální aktivity resp. kožní vodivosti a měření elektrické aktivity mozku pomocí EEG. Tato data pak obvykle slouží pro účely identifikace různých kognitivních či afektivních stavů (např. radost, úzkost, zaujetí úkolem či naopak rozptýlenost apod.) či měření jejich intenzity v průběhu učení nebo při řešení nějakého úkolu (např. míra kognitivní zátěže, intenzita prožívání pozitivních či negativních emocí apod.).

- **Analýza afektivních stavů (*affective state analysis*).** Blikstein a Worsley (2016) zmiňují jako samostatnou oblast multimodální analytiky učení i analýzu afektivních stavů. Tu lze však do značné míry vnímat jako překrývající se s oblastí modelování emocí a afektivních stavů, která byla představena výše v souvislosti s modelováním studentů (viz 2.3.3.3. *Modelování emocí a afektivních stavů*). Jako určitý rozdíl je snad možné vnímat to, že zatímco v případě modelování emocí a afektivních stavů studentů je obvykle věnována větší pozornost modelování těchto stavů při využívání online výukového systému (typicky ITS), přičemž jako data slouží především videozáznamy obličeje studenta při používání daného systému, v případě analýzy afektivních stavů v kontextu multimodální analytiky učení je věnována pozornost afektivním stavům i v jiných vzdělávacích kontextech, kde jsou pak pro sběr dat využívány například i různé biofyzilogické senzory.

Za do určité míry separátní, a zároveň multimodální analytikou všeprostopující téma výzkumu, je pak možné považovat otázky týkající se kombinace a integrace záznamů výše nastíněných modalit a různých typů dat do jednoho smysluplného celku. Ať již pro účely konkrétní analýzy nebo obecně za účelem komplexnějšího porozumění učení (Blikstein & Worsley, 2016; Ochoa, 2017; Worsley, 2018).

### **2.3.7. Etické aspekty analytiky učení a data miningu ve vzdělávání**

Jako poslední z témat výzkumu v oblasti analytiky učení a data miningu ve vzdělávání je možné uvést problematiku etických aspektů souvisejících s aplikací analytických a data miningových metod a nástrojů ve vzdělávání. Této oblasti se přitom začala věnovat větší pozornost až se vznikem analytiky učení (tj. kolem roku 2012) a i nadále je tato problematika řešena spíše v souvislosti s analytikou učení než s data miningem ve vzdělávání. Určitou roli v tomto ohledu zřejmě sehrává i to, že analytika učení má silnější kořeny v sociálních a humanitních vědách, zatímco data mining ve vzdělávání je více technickou disciplínou. Z raných publikací, které se etických aspektů dotýkají nebo se na ně přímo zaměřují, lze pak

uvést především práce Dringuse (2012), Fergusonové (2012a), Grellera a Drachslera (2012), Siemense (2012) či Sladeové a Prinslooa (2013). Tyto autory a jejich publikace lze považovat za první iniciátory odborné diskuze věnující se tématu etických aspektů analytiky učení.

Zároveň, jak se postupně analytika učení dostávala do stále širšího povědomí, a na řadě univerzit začaly být využívány různé analytické nástroje, přibývaly do diskuze etických aspektů další publikace řešící otázky, kterým doposud nebyla věnována patřičná pozornost. Velmi užitečným materiálem se v tomto kontextu ukázal být přehled literatury, který podal Sclater (2014). V něm identifikoval 15 řešených oblastí a v nich celkem 93 otázek, které si pokládají autoři věnující se etickým aspektům v souvislosti s analytikou učení. Lze zmínit například otázky jako: Kdo má vlastnit data, která jsou automaticky generována a následně uchovávána při používání různých vzdělávacích systémů? Má mít student možnost zakázat sběr a analýzu dat o své osobě? Kdo má mít přístup ke studentským datům? Má univerzita právo poskytovat data o studentech třetím subjektům? Sclaterův (2014) přehled literatury pak byl využit při tvorbě kodexu praxe analytiky učení (*code of practice for learning analytics*), na jehož tvorbě se podílel rovněž především Sclater (2016).

Mimo práci Sclatera je pak téma etických ale i legislativních aspektů analytiky učení stále více rozvíjeno i dalšími autory v této oblasti (např. Krumm, Means, & Bienkowski, 2018; Pardo & Siemens, 2014; Prinsloo & Slade, 2017). Za poměrně zásadní příspěvek do odborné diskuze věnující se této problematice lze pak považovat speciální číslo časopisu *Educational Technology Research and Development* s názvem *Exploring the Relationship of Ethics and Privacy in Learning Analytics and Design*, které se věnovalo právě tomuto tématu (viz tabulka 2). Zároveň je v průběhu času v této odborné diskuzi patrný určitý posun od spíše základních a jednodušších (a spíše legislativních) otázek týkajících se např. informovanosti uživatelů či ochrany osobních údajů, ke stále komplexnějším a náročnějším etickým otázkám týkajícím se například diskriminace a dalších nepříznivých důsledků, které může využívání analytiky a data miningu ve vzdělávání přinášet. V následujících bodech pak podávám základní přehled témat, která jsou v oblasti etických a legislativních aspektů analytiky učení řešena:

- **Informovanost, transparentnost a souhlas.** Již Sladeová a Prinsloo (2013) poukazovali na to, že mnoho studentů v současnosti zřejmě ani neví, jaká data o nich škola či univerzita sbírá, a jak je případně analyzuje. Nabízí se tudíž otázka, jestli by v oblasti analytiky učení neměla existovat povinnost informovat studenty o tom, jaká data jsou o nich sbírána. Zároveň je otázkou, zda by mělo být povinné od studentů získávat informovaný souhlas, jako je tomu zvykem v jiných oblastech či u jiných typů výzkumů. Zde ovšem záleží na vymezení a pojetí analytiky učení.

Budeme-li analytiku učení chápat jako běžnou oblast výzkumu, pak lze pouze aplikovat etické standardy používané v jiných disciplínách (např. etická komise apod.). Analytiku učení však můžeme chápat také jako specifickou oblast výzkumu, která vyžaduje specifické či nové mechanismy dohledu. Případně může být analytika učení vnímána nikoli jako oblast výzkumu nýbrž jako oblast vzdělávací praxe, což by s sebou neslo opět jiné důsledky (srov. Willis III, Slade, & Prinsloo, 2016). V každém případě je ale důležitost informovanosti a souhlasu (primárně) studentů stejně jako celkové transparentnosti způsobu aplikace analytiky učení relativně všeobecně přijímána (srov. např. Pardo & Siemens, 2014; Prinsloo & Slade, 2017; Sclater, 2016, 2017). Přesto, i v této oblasti zůstávají další otázky k řešení. Mají být například studenti informováni pouze o tom, jaká data jsou o nich sbírána, nebo mají být informováni i o dalších souvislostech (např. pro jaké účely jsou data sbírána, jakým způsobem jsou data ukládána, zpracovávána, analyzována apod.)? A pokud ano, do jaké míry podrobnosti (např. mají vědět i o konkrétních algoritmech, které jsou při analýze použity)?

- **Ochrana osobních údajů.** S výše uvedeným souvisí i problematika ochrany osobních údajů, která je v současnosti již do určité míry řešena i legislativně. Např. v kontextu Evropské unie vzbudilo značnou pozornost tzv. obecné nařízení o ochraně osobních údajů (*general data protection regulation*) známé od zkratkou GDPR, na které musely reagovat i univerzity či vysoké školy využívající aplikace a systémy na bázi analytiky a data miningu. Ostatně i systém Moodle, kterému se věnuje tato práce, nabízí od verze 3.5 speciální modul přinášející novou funkcionalitu tak, aby mohlo být využívání systému v souladu s požadavky GDPR. Zde je však třeba si uvědomit, že existující nařízení a dostupná funkcionalita na straně daného systému jsou jedna věc, ale konkrétní aplikace ochrany osobních údajů v rámci instituce je věc druhá. Zároveň je třeba odlišovat osobní údaje v legislativním smyslu a osobní či citlivé údaje na základě toho, jak je vnímají sami studenti. Ifenthaler a Schumacher (2016) například ve svém výzkumu ukazují, že studenti jsou poměrně často ochotni pro účely analytického systému sdílet data o jejich univerzitním studiu (např. zapsané kurzy, výsledky v testech apod.), ale naopak spíše nejsou ochotni sdílet data považující za osobní (např. příjem, bydliště, ale i v pedagogickém výzkumu poměrně běžně zjišťované údaje jako rodinný stav či vzdělání rodičů). Dále nejsou příliš ochotni sdílet data týkající se jejich chování v online vzdělávacím systému (např. časy přístupů, počet stažení apod.) nebo data produkovaná mimo vzdělávací systém (např. data ze sociálních sítí).

- **Možnost neúčasti (princip opt-out)<sup>79</sup>.** V souvislosti s informovaností, a zvláště se souhlasem si pak někteří výzkumníci (např. Pardo & Siemens, 2014; Sclater, 2017) pokládají otázku, zda mají mít studenti možnost odmítnout, aby o nich byla určitá data sbírána, analyzována a používána např. pro predikci úspěšnosti či poskytnutí doporučení. Samotný smysl poskytování souhlasu se sběrem dat totiž spočívá právě v tom, že student reálnou možnost souhlas neposkytnout. Většina běžných aplikací či služeb vyžadujících souhlas (např. pro přístup k určitým datům) přitom funguje tak, že pokud uživatel souhlas neudělí, pak danou aplikaci či službu vůbec nemůže využívat. Tento režim je ale jen obtížně přenositelný do oblasti vzdělávání, jelikož by vedl k nemožnosti nadále pokračovat ve vzdělávání. Těžko si lze například představit situaci, kdy by univerzita využívala nějaký online vzdělávací systém (např. Moodle), který o svých uživatelích běžně sbírá řadu údajů, a zároveň by studentům umožňovala odmítnout tento systém využívat. Navíc využívání principu opt-out má vliv i na ty studenty, kteří chtějí poskytovat svá data a využívat tak možností určitého analytického systému z těchto dat pramenící (např. v případě systému včasného varování). Lze si tak představit situaci, kdy velké množství studentů odmítne poskytnout data, což následně povede k méně reprezentativnímu vzorku, a tudíž k horším predikcím v rámci systému včasného varování. Sclater (2017) tak uvádí, že odmítnutí účasti (tj. princip opt-out) lze vnímat také jako sobecký čin, který znemožňuje ostatním využívat službu či funkcionalitu, kterou by využívat chtěli. Můžeme se tak dostat až k etickým otázkám týkajícím se toho, kdy užitek pro skupinu lidí převáží právo jednotlivce na odmítnutí účasti, které se běžně řeší např. v oblasti medicíny a medicínského výzkumu (Pardo & Siemens, 2014; Slade & Prinsloo, 2013).
- **Validita dat a z nich vyvozovaných predikcí.** Další oblast etických otázek souvisí s validitou sbíraných dat a z nich generovaných predikcí či doporučení. Na jedné straně univerzity tak jako tak v současnosti automaticky sbírají velké množství dat o studentech a jejich učení, takže lze argumentovat, že je ne-etické, pak přinejmenším nezodpovědné, tato data nevyužívat pro dosahování vzdělávacích cílů studentů (Slade & Prinsloo, 2013; Sclater, 2017). Na druhé straně

---

<sup>79</sup> Principem „opt-out“ se má na mysli mechanismus, který uživateli umožňuje odstoupit od účasti (např. v určitém sběru dat či jejich analýze). Jde tedy o situaci, kdy jsou o studentovi automaticky sbírána data pro účely nějakého analytického systému, ale studentovi je zároveň dána možnost říci, že nechce, aby o něm tato data byla nadále sbírána. Opačným principem je pak princip „opt-in“, u kterého nedochází k žádnému sběru dat o studentovi, dokud se sám student nepřihlásí k tomu, že chce, aby o něm byla daná data pro dané účely sbírána.

mohou být tato data zkreslená či jiným způsobem problematická, případně mohou být nevhodným způsobem analyzovaná. Tím může docházet k nevalidním predikcím či doporučením, které mohou v důsledku studentům škodit místo pomáhat. Zároveň, jak upozorňuje např. Sclater (2017), v řadě případů může docházet k tomu, že je velmi obtížné vůbec zhodnotit validitu vyvozovaných predikcí. Zvláště pak v případech, kdy univerzity využívají proprietární řešení dodávané externím poskytovatelem, a tudíž nemají přesnou představu o tom, jak jsou predikce generovány.

- **Manipulace analytických metrik studenty.** S validitou dat a predikcí, ale zároveň také s výše nastíněnými otázkami informovanosti a transparency, pak úzce souvisí problémy týkající se záměrné manipulace studentů s určitými daty či analytickými metrikami (srov. Sclater, 2017). Tím, že studenti ví, že jsou data o jejich chování sbírána a analyzována, mohou se je snažit ovlivňovat v jejich prospěch. A čím více je daný analytický systém transparentní, tím snáze samozřejmě může být ovlivnitelný. Objevuje se tak etické dilema, kdy na jedné straně stojí informovanost studentů a transparentnost analytického řešení, a na druhé straně větší možnosti studentů takové transparentní řešení manipulovat a znehodnotit tak jeho výstupy.
- **Nepříznivé dopady analytiky a data miningu ve vzdělávání.** Mimo záměrnou manipulaci pak může informovanost studentů o používaném analytickém systému vést k dalším nepříznivým důsledkům. Například může povědomí studentů o tom, že je jejich chování v online vzdělávacím systému monitorováno, vést k nežádoucí změně jejich chování v tomto systému, případně k vyhýbání se používání systému jako takového. Jiným příkladem nepříznivého dopadu, který vedle Sclatera (2017) zmiňují např. Lawson, Beer, Rossi, Moore a Fleming (2016), je demotivace některých studentů spojená s identifikací rizikových studentů a systémy včasného varování. Zatímco někteří studenti mohou být motivováni k intenzivnější práci poté, co jsou upozorněni, že jim hrozí nedokončení kurzu, jiní studenti mohou motivaci k další práci naopak ztratit. Případně mohou ztratit sebevědomí, že by kurz mohli úspěšně ukončit, a tudíž se o to raději přestanou jakkoli snažit. V důsledku tak může prediktivní systém vést k přesnému opaku, než bylo jeho původním záměrem (tj. pomáhat studentům, kterým hrozí neúspěch). V souvislosti s adaptivními a doporučovacími systémy pak Sclater (2017) zmiňuje potenciální nepříznivý dopad v tom, že mohou vést ke ztrátě autonomie studentů v procesu jejich vlastního učení. Student tak může pouze slepě

sledovat nejrůznější návrhy či doporučení (např. na kurzy či studijní materiály, které má dále studovat), místo aby se sám rozhodoval a volil si vlastní cestu na základě vlastních studijních cílů. V širším kontextu a v rámci dlouhodobých efektů lze pak u doporučovacích systémů upozornit rovněž na problém tzv. informačních bublin (*filter bubbles*)<sup>80</sup>. Ty mohou ve vzdělávacím kontextu vznikat například v situacích, kdy doporučovací systém funguje na principu podobnosti a doporučuje tak studentům ke studiu podobné studijní materiály či kurzy, anebo takové materiály, které studovali jemu podobní studenti apod. Případně může doporučovací systém fungovat tak, že bude doporučovat takové studijní materiály, které vedou k rychlému či snadnému ukončení kurzu. Ve všech těchto případech pak může v konečném důsledku docházet k tomu, že student bude uzavřen do informační bubliny podobných či povrchních informací, místo aby se setkával s diverzitou a rozšiřoval si své znalosti a obzory (Bozdag, 2013; Pariser, 2011).

## 2.4. Shrnutí a východiska pro empirickou část

Cílem této přehledově pojaté kapitoly bylo zevrubné představení oblastí označovaných jako data mining ve vzdělávání a analytika učení, které jsou zvláště v posledních letech stále více akcentovány ve výzkumu i praxi vzdělávání v souvislosti s e-learningem. V první části jsem nejprve zmapoval vznik a historické kořeny obou oblastí, aby byl patrný kontext, ze kterého tyto oblasti a výzkumníci v nich se pohybující vycházejí. V druhé části jsem představil analytiku učení a data mining ve vzdělávání jako takové. Podal jsem jejich přesnější vymezení, představil související pojmy a koncepty a popsal používané metody a obvyklé typy analyzovaných dat. Ve třetí části jsem pak nastínil hlavní směry či témata výzkumů, která jsou v těchto oblastech řešena a publikována.

Analytika učení a data mining ve vzdělávání jakožto svébytné výzkumné oblasti jsou stále velmi mladé a jejich věk lze zatím měřit spíše v řádu jednotek let, resp. můžeme mluvit o tom, že se pohybují na přelomu první a druhé dekády své existence. Prozatím tak stále zůstává do značné míry nejasné, jaký a jak velký dopad budou mít tyto oblasti na pedagogický výzkum a na učení, výuku a vzdělávání obecně. Přesto je již nyní patrné, že jde o oblasti, jež se v současnosti relativně rychle vyvíjí a které tak mají potenciál zanechat určitou stopu ve vzdělávání a v pedagogickém výzkumu. Ať již díky tomu, že přitahují neustále se rozšiřující

---

<sup>80</sup> Někteří autoři v českém kontextu používají doslovnější překlady jako „filtrová bublina“ či „filtrační bublina“. Ovšem vzhledem k tomu, že podstata *filter bubbles* spočívá ve filtrování informací, jež se k subjektu dostanou, přikláním se k označení „informační bublina“, které se v českém jazyce jeví jako přiléhavější. Ke stejnému překladu se přiklání i další autoři, např. Rathouz (2017).

komunitu výzkumníků z různých oborů, která rozvíjí stávající i nové metody a techniky analýzy vzdělávacích dat, anebo díky tomu, že stále více vzdělávacích institucí začíná analytice učení a data miningu ve vzdělávání věnovat určitou pozornost a zkouší experimentovat s implementací nějakého analytického nástroje či systému. Významným aspektem pak může být i to, že se toto téma (zvláště tedy analytika učení) začíná dostávat i do důležitých strategických dokumentů jako je například tzv. *Digital Education Action Plan* (Digital, 2018), což má potenciál ještě více umocnit další rozšiřování a zavádění analytiky a data miningu do vzdělávací praxe.

Výsledky výše nastíněného přehledu dosavadních výzkumů v oblasti analytiky učení a data miningu ve vzdělávání lze – zvláště co se týče jejich důsledků pro další části práce – shrnout v několika základních bodech. Především je třeba mít na paměti, že ať už v rámci výzkumu analytiky učení a data miningu ve vzdělávání nebo pak i při samotném implementování konkrétních analytických či data miningových řešení, stále jde v těchto oblastech do značné míry o experimentální fázi. To ostatně potvrzují i výsledky realizovaných přehledových studií, kdy například Papamitsiouová a Economides (2014) ukazují, že většina publikovaných studií má explorační či experimentální charakter. Současnou fází vývoje těchto oblastí lze zároveň považovat do značné míry za divergentní, kdy řada výzkumníků věnuje pozornost značně široké škále přístupů, témat či metod. To má na jedné straně pozitivní důsledky v tom, že se tím zachycuje a mapuje širě celé problematiky, na druhé straně to však přináší i jistou roztržičnost. Vzniká tak velké množství velmi úzce zaměřených analýz, jejichž výsledky jsou sice zajímavé a mnohdy slibné, ale zároveň velmi specifické. A to především v tom smyslu, že neumožňují dostatečné zobecnění nebo je nelze použít v jiném kontextu. Určitou výzvou pro další rozvoj analytiky učení a data miningu ve vzdělávání je tak posun od této rozbíhavé experimentální fáze směrem k fázi konvergentní, v rámci které by již probíhal systematický a dostatečně hluboký výzkum přinášející zobecnitelné výsledky či výsledky platné napříč různými vzdělávacími kontexty.

S výše uvedeným do jisté míry souvisí i rozdílné cíle, jaké si výzkumníci v oblasti data miningu ve vzdělávání a analytiky učení kladou. Vzhledem k tomu, že nejde o ryze výzkumné oblasti, nýbrž o oblasti často propojené s praktickou či aplikační stránkou, stanovované cíle jsou mnohdy primárně praktického charakteru. Při určité míře zjednodušení tak můžeme v rámci dosavadních publikací rozlišit dva nejčastější typy cílů: predikce versus explorační. Zatímco v případě exploračních studií jde často o snahu hlouběji a podrobněji zkoumat, jakým způsobem se studenti v online prostředí chovají a učí, v případě studií zaměřených na predikci jde obvykle o snahu přijít s co možná nejlepším prediktivním modelem (např. pro predikci úspěšnosti resp. neúspěšnosti v kurzu) za účelem jeho využití v konkrétním



vzdělávacím kontextu. S oběma typy cílů se přitom pojí omezení naznačené již v předchozím odstavci. Řada studií se zaměřuje na konkrétní kurzy, typy kurzů či specifické typy online vzdělávacích prostředí a zůstává tak velkou otázkou, nakolik jsou zjištěné výsledky platné i pro jiné kurzy či typy kurzů a zda k obdobným výsledkům dojdeme i v jiných online vzdělávacích systémech. V případě predikce je otázkou např. to, zda navržený prediktivní model bude fungovat i v jiném více či méně odlišném kurzu. V případě explorační je pak třeba se ptát, jestli je například určitý způsob chování studentů v kurzu vázaný pouze na konkrétní situaci v konkrétním kurzu, anebo jde o obecnější aspekt učení studentů v online kurzech.

Zároveň je patrné, že v analytice učení a data miningu ve vzdělávání již nejde výhradně o technickou problematiku zaměřující se primárně na technické aspekty online vzdělávacích systémů (jako se to mohlo zdát v raných fázích vývoje těchto oblastí). V současnosti se jedná o výrazně širší výzkumné pole, v rámci kterého si výzkumníci kladou mimo jiné i ryze pedagogické otázky týkající se učení a vzdělávání v různých vzdělávacích prostředích. V kontextu online vzdělávacích prostředí se tak objevují nové specificky zaměřené výzkumné oblasti jako například analytika vzdělávacích videí zkoumající různé parametry videí využívaných ve vzdělávání (např. délka, styl, rychlost) a jejich vliv na učení v online prostředí (Guo, Kim & Rubin, 2014; Kim et al., 2014) nebo analytika emocí (*emotional learning analytics*, viz D'Mello, 2017), v rámci které výzkumníci věnují pozornost nejen kognitivním stavům studentů, ale také jejich emocím a afektivním stavům souvisejícím s jejich učením. Realizované výzkumy se také již neomezují pouze na virtuální či online prostředí. Metody analytiky učení a data miningu ve vzdělávání se tak začínají využívat i v kontextu tradiční kontaktní výuky. Zvláště pod hlavičkou tzv. multimodální analytiky učení (Ochoa, 2017) se začíná pracovat s různými typy záznamových zařízení, senzorů či detektorů, které umožňují shromažďovat data nejen z virtuálního, ale i z „reálného“ vzdělávacího prostředí. To přitom naznačuje potenciál data miningu ve vzdělávání a analytiky učení přispět k pedagogickému výzkumu nejen výhradně v kontextu e-learningu, ale i v mnohem větší šíři.

Na druhou stranu stále zůstává řada výzkumných témat, kterým je doposud v analytice učení a data miningu ve vzdělávání věnována pouze relativně malá pozornost. Jedním z takových témat je oblast blended learningu, i když se v posledních letech zájem o toto téma mírně zvyšuje. Na jedné straně je pochopitelné, že je v rámci analytiky učení a data miningu ve vzdělávání věnována větší pozornost spíše online kurzům, u kterých lze předpokládat, že všechny důležité aspekty probíhají skrze online prostředí, a tudíž jsou alespoň potenciálně zachytitelné a analyzovatelné pomocí běžných analytických a data miningových metod. Na druhé straně se zvláště v kontextu terciárního vzdělávání velmi často setkáme spíše s blended kurzy než s výhradně online kurzy. Blended learning tak už jen četností svého využití tvoří

nezanedbatelné téma. Jiným příkladem doposud okrajového tématu jsou učitelé. Naprostá většina výzkumů v oblasti analytiky učení a data miningu ve vzdělávání se věnuje analýzám chování studentů. Přitom učitel je zásadním aktérem i v kontextu online vzdělávání, proto by jistě přinesly důležité výsledky i studie a analýzy zaměřené na učitele a jejich chování v online vzdělávacích prostředích. Důležitost učitelů jakožto výzkumného tématu si však již někteří autoři začínají uvědomovat a např. D’Mello (2017) tak začíná hovořit o analytice učitelů (*teacher analytics*) jako o jednom z vynořujících se témat výzkumu v této oblasti.

S ohledem na výše uvedené jsem se rozhodl nepojímat empirickou část práce úzce a nezaměřovat se pouze na jeden konkrétní kurz či několik málo specificky vybraných kurzů. Naopak se chci pohybovat na obecnější úrovni, což by mi potenciálně umožňovalo odhalit obecnější aspekty chování a učení studentů v LMS Moodle, které by byly platné napříč různými kurzy a v ideálním případě i napříč různými systémy typu LMS. Co se týče prediktivně a exploratorně orientovaných výzkumných cílů, oba jsou dle mého názoru v kontextu analytiky učení a data miningu ve vzdělávání legitimní a oběma se chci zabývat v empirické části práce. Zároveň ale kladu větší důraz na exploratorně orientovaný výzkum, jelikož jsem spolu s Gaševicem et al. (2016) přesvědčen, že výzkum v oblasti data miningu ve vzdělávání a analytiky učení je ve fázi, kdy je nejprve nutný hlubší exploratorní výzkum, než bude možné přistoupit k vývoji dostatečně funkčních a zároveň obecných prediktivních modelů. Stejně jako většina výzkumů v této oblasti se pak i v empirické práci hodlám zaměřovat primárně na studenty a jejich chování v online vzdělávacím prostředí. Na druhou stranu chci jistou pozornost věnovat i učitelům, kteří jsou zatím poněkud opomíjeni. Konkrétní popis metodologického pojetí empirické části práce nabízí následující kapitola.

### 3. Metodologie výzkumu

V této metodologické části práce představuji postup, který byl zvolen při řešení disertačního projektu. V následující podkapitole nejprve nastíním téma výzkumu a následně představím hlavní výzkumné cíle, podle kterých byl zvolen výzkumný design. Vzhledem k tomu, že je v této práci použit poměrně netradiční výzkumný design v podobě série exploratorně pojatých výzkumných sond, jsou v druhé podkapitole podrobněji popsána a vysvětlena kritéria, na základě kterých bylo zvoleno konkrétní tematické zaměření jednotlivých výzkumných sond. Třetí podkapitola podává stručný přehled hlavních a dílčích výzkumných otázek celé disertační práce. Jak již bylo naznačeno v úvodní kapitole, tato disertační práce sleduje vedle otázek věcných či meritorních také otázky metodologické. Proto jsou v rámci třetí podkapitoly hlavní i dílčí výzkumné otázky rozděleny na otázky věcné a otázky metodologické.

Zbývající tři podkapitoly se pak zaměřují na metody sběru a analýzy dat, etické aspekty a limity spojené s výzkumem realizovaným v rámci mého disertačního projektu. V souvislosti s popisem metod sběru a analýzy dat je třeba zmínit, že v této části bude podán pouze základní popis postupu, jakým probíhalo získávání dat a jejich následná analýza. Podrobnější informace jsou pak vždy uváděny až v následujících kapitolách, které se věnují přímo jednotlivým sondám (tj. kapitoly 4 až 6), kde má každá z kapitol rovněž svou vlastní metodologickou podkapitolu. Primární úlohou této obecné metodologické kapitoly je totiž poskytnout čtenáři veškeré potřebné informace o metodologickém postupu práce jakožto celku, aby si tak mohl udělat jasnou představu, jak celý disertační projekt probíhal.

#### 3.1. Výzkumné téma, cíle a design výzkumu

**Výzkumným tématem** této disertační práce je využití metod analytiky učení a data miningu ve vzdělávání pro analýzu učení a výuky v online systémech typu LMS (tj. systémy pro řízení výuky). K vymezení základních pojmů použitých v předchozí větě již došlo na předchozích stranách práce v první a druhé kapitole. Nyní je tedy možné přesunout pozornost k samotné formulaci tématu a k jeho zdůvodnění. V rámci formulace tématu totiž záměrně akcentuji dva různé aspekty, které jsou v této disertační práci problematizovány a kterými se v práci zabývám. Na jedné straně stojí problematika učení a výuky či obecně vzdělávání prostřednictvím systémů pro řízení výuky, které lze považovat za specifickou kategorii online vzdělávacích prostředí. Na druhé straně pak stojí problematika aplikace analytických metod a technik rozvíjených zvláště v oblastech označovaných jako data mining ve vzdělávání a analytika učení na data pocházející ze systémů typu LMS. Uvedenou formulací výzkumného

tématu tak naznačuji, že předkládaná disertační práce sleduje jednak věcnou rovinu, jednak také rovinu metodologickou.

Maxwell (2013) rozlišuje tři různé druhy cílů pro realizaci výzkumu. Jde o osobní cíle, praktické cíle a intelektuální či vědecké cíle. Tyto kategorie lze dle Maxwella zároveň chápat jako tři různé oblasti motivace vedoucí výzkumníky k výběru určitého výzkumného tématu, proto je využiji k načrtnutí hlavních důvodů pro volbu uvedeného výzkumného tématu. V souvislosti s osobními cíli vycházela volba tématu z mého dosavadního zájmu o problematiku moderních technologií ve vzdělávání. Po zkušenostech s kvalitativními výzkumnými postupy v rámci mé magisterské diplomové práce (Juhaňák, 2011) mě však lákalo využití naopak spíše kvantitativních výzkumných postupů. Co se týče praktických cílů, byla volba tématu disertačního projektu ovlivněna mým někdejší působením na pozici e-learningového specialisty v rámci Centra informačních technologií Filozofické fakulty Masarykovy univerzity a pod projektem FIFA (Filozofická fakulta jako pracoviště excelentního vzdělávání)<sup>81</sup>. Využití metod data miningu ve vzdělávání a analytiky učení se přitom nabízelo jako jedna z možností, jak přispět ke zvyšování kvality výuky a učení v LMS, a to především díky tomu, že tyto metody mohou vyučujícím poskytovat lepší vhled do „dění“ v jejich e-learningových kurzech. V rámci intelektuálních či vědeckých cílů, které se zaměřují primárně na porozumění nějakému problému či fenoménu, byla volba výzkumného tématu vedena především snahou o hlubší porozumění otázkám učení a výuky v online prostředí, specificky pak ve výukových prostředích typu LMS. Oblasti data miningu ve vzdělávání a analytiky učení přitom nabízely příslib poskytnutí zcela nového úhlu pohledu na tuto problematiku. Navíc byly tyto výzkumné oblasti na začátku mého doktorského studia ve svých úplných počátcích (zvláště analytika učení), což zároveň otevíralo možnost věnovat se v českém pedagogickém výzkumu doposud téměř neřešené problematice, a tím pádem přispět nejen k obsahu, ale i k metodologii českého pedagogického výzkumu věnujícího se otázkám informačních a komunikačních technologií ve vzdělávání.

Výše nastíněným dvěma rovinám výzkumného tématu zároveň odpovídají dva **hlavní výzkumné cíle**, které si tato disertační práce klade. S oporou o základní typy výzkumných cílů v sociálněvědním výzkumu, jak je uvádí Blaikie (2003), je možné za věcný či meritorní cíl této práce považovat exploraci a popis toho, jakým způsobem probíhá učení a výuka

---

<sup>81</sup> Celým názvem *Filozofická fakulta jako pracoviště excelentního vzdělávání: Komplexní inovace studijních oborů a programů na FF MU s ohledem na požadavky znalostní ekonomiky (CZ.1.07/2.2.00/28.0228)*. V rámci projektu jsem působil jako metodologická podpora vyučujících, kteří se podíleli na tvorbě či inovaci svých e-learningových kurzů a opor v prostředí LMS Moodle. V rámci projektu došlo k tvorbě či inovaci více jak 500 e-learningových kurzů.

v systémech pro řízení výuky, specificky pak v LMS Moodle používaném na Filozofické fakultě MU. Metodologickým cílem práce je pak zmapování používaných analytických metod a technik v oblasti analytiky učení a data miningu ve vzdělávání a kritické zhodnocení jejich potenciálního přínosu pro výzkum učení a výuky v systémech pro řízení výuky a pro pedagogický výzkum obecně.

Od uvedeného výzkumného tématu a stanovených výzkumných cílů se následně odvíjí zvolený výzkumný přístup resp. **design výzkumu**. Zaměření na oblasti analytiky učení a data miningu ve vzdělávání, kteréžto se věnují využívání a rozvoji především kvantitativně orientovaných výzkumných technik, znamenalo automaticky volbu kvantitativního výzkumného přístupu. Jak jsem ovšem naznačil v první kapitole, zvláště pak v části *1.3.1. Exploratorní analýza dat jako součást kvantitativního výzkumu*, nejedná se v případě této práce o v české pedagogice (ale nejen tam) obvykle volený kvantitativní výzkumný přístup, který lze chápat jako konfirmační a zaměřující se především na ověřování hypotéz. Naopak, jde o exploratorně orientovaný kvantitativní výzkum navazující na kvantitativní výzkumnou tradici, kterou započal Tukey (1962, 1977) a kterou v českém kontextu alespoň krátce zmiňuje například Hendl (2012).

To, že jsem se vydal cestou exploratorního kvantitativního výzkumu s sebou ovšem neslo nemožnost postupovat některým ze zavedených výzkumných designů (srov. např. Blaikie, 2003; Cohen, Manion, & Morrison, 2007; Creswell, 2009; Maxwell, 2013). Tudíž bylo nutné navrhnout si výzkumný postup do značné míry vlastní. S ohledem na stanovené výzkumné téma a cíle jsem tudíž přistoupil k výzkumnému designu, který by bylo možné popsat jako sérii specificky zaměřených výzkumných sond. Tento postup mi dovolil naplnit stanovené výzkumné cíle ve dvou důležitých ohledech. V případě věcného cíle, který se týká učení a výuky v systémech typu LMS, mi umožnil věnovat se různým aspektům vyučování v LMS, a tím pádem postihnout určitou šíři této problematiky. Zároveň mi takový přístup dovolil zkoumat zvolenou problematiku na dostatečné úrovni detailu, aby bylo možné rozšířit zjištěnými výsledky dosavadní poznání v této oblasti. V případě metodologického cíle jsem pak díky tomuto postupu mohl získat širší přehled o metodologii analytiky učení a data miningu ve vzdělávání a zároveň jsem měl možnost v rámci jednotlivých sond aplikovat různé typy analytických metod a technik, což mi zajistilo dostatečný vhled do problematiky související s využíváním těchto metod.<sup>82</sup>

---

<sup>82</sup> Pokud bych pro představení zvoleného výzkumného designu použil poněkud metaforické, ale snad zároveň ilustrativní vyjádření, pak si lze výzkumné téma či obecně problematiku, které se v této práci věnuji, představit v podobě koule, kdy její povrch tvoří různé perspektivy a přístupy, jakými lze ke zkoumání problému přistupovat, ale také různá témata a dílčí výzkumné oblasti v rámci dané problematiky. Naopak střed koule tvoří jádro

Pro přehlednost je navržený výzkumný design schematicky znázorněn na obrázku níže (viz obrázek 13). Výchozím bodem výzkumu je široce pojatá přehledová studie mapující oblasti data miningu ve vzdělávání a analytiku učení, která byla prezentována v předchozí kapitole (viz kapitola 2). Na tu následně navazuje série paralelních výzkumných sond. Paralelními jsou přitom sondy v tom smyslu, že na sebe jednotlivé sondy nenavazují (tj. např. sonda B nenavazuje na výsledky sondy A), nýbrž se každá věnuje do značné míry separátnímu tématu. Vždy ovšem v kontextu učení a výuky v systémech pro řízení výuky a za využití analytických postupů data miningu ve vzdělávání a analytiku učení. V jednotlivých sondách je pak uplatňován běžný výzkumný postup empirického výzkumu. Tomu přitom odpovídá i struktura textu, kdy je každá ze sond prezentována za využití pěti základních částí:

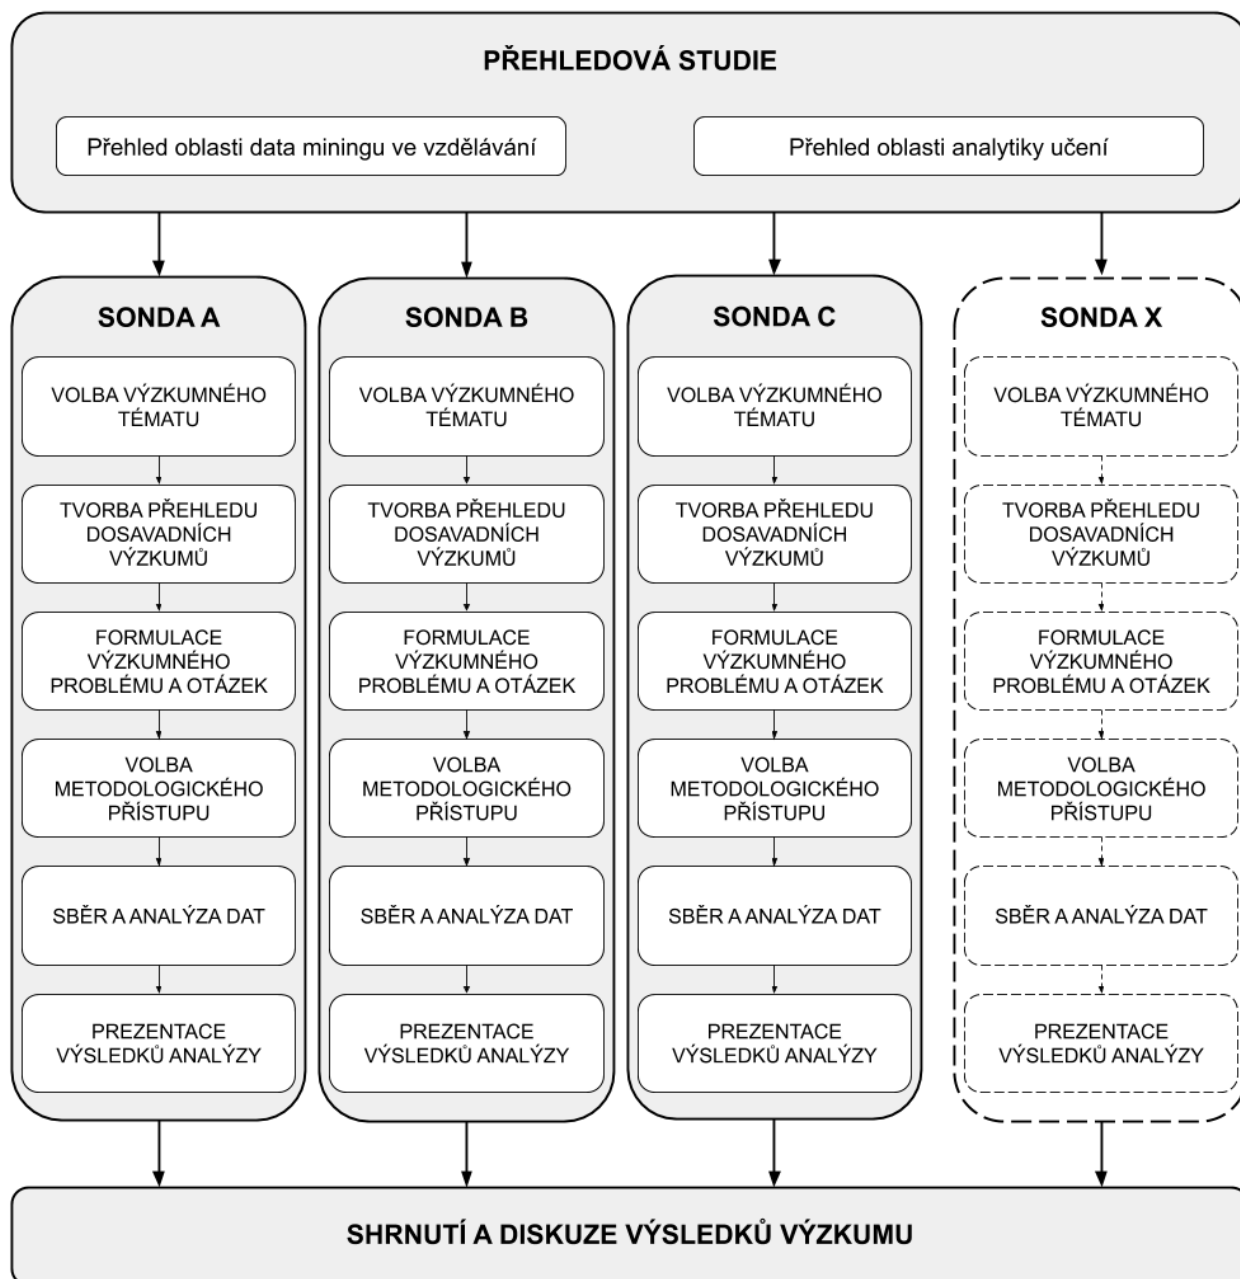
1. zmapování dosavadních výzkumů týkajících se tématu dané sondy,
2. explicitní formulace výzkumného problému či otázek,
3. popis metodologického postupu,
4. prezentace výsledků analýz a
5. závěrečná diskuze výsledků a sondy jako celku.

Na dílčí sondy pak navazuje závěrečná obecná diskuzní část disertačního výzkumu jako celku, v níž přesunuji pozornost zpět na úroveň hlavních výzkumných cílů práce. S oporou o výsledky široce pojaté přehledové studie a výsledky série úzce zaměřených empirických sond má pak v závěrečné části práci dojít k naplnění těchto cílů a zodpovězení hlavních výzkumných otázek.

Na závěr této části pak zbývá doplnit, že v níže uvedeném schématu naznačuje Sonda X fakt, že počet realizovaných sond nebyl předem pevně stanoven či omezen. Naopak, v průběhu práce na disertačním projektu jsem postupně rozpracovával různá témata a mimo tři „finální“ sondy prezentované v této práci jsem pracoval i na několika dalších sondách

---

problému, ke kterému se jednotlivé výzkumy snaží dostat. Při výzkumu problematiky tak postupujeme od povrchu koule směrem k jejímu středu. Výzkumný postup v podobě série specificky zaměřených výzkumných sond mi umožňuje vyhnout se dvěma do jisté míry krajním a zároveň, jak věřím, neproduktivním přístupům. Na jedné straně by bylo možné usilovat o co možná nejúplnější pokrytí problematiky jako celku. Tím by ovšem hrozilo riziko, že by se výzkum pohyboval pouze po povrchu oné koule a nepronikl tak do dostatečné hloubky. Na druhé straně by bylo možné zaměřit se pouze na jedno úzce zaměřené téma, což by sice dovolilo proniknout do dostatečné hloubky, ovšem za cenu značného zúžení pozornosti jen na velmi úzkou část zkoumané problematiky. Využití série dílčích výzkumných sond mi tak dává možnost přistupovat ke zkoumání problematiky (tj. oné pomyslné koule) z různých stran a perspektiv, a zároveň se nepohybovat pouze na povrchu tématu, nýbrž proniknout do dostatečné hloubky.



Obrázek 13: Schéma naznačující výzkumný design disertační práce.

týkajících se zkoumané problematiky. S ohledem na rozsah práce, výsledné tematické zaměření práce, a především obsahovou a metodologickou závažnost resp. přínos jednotlivých sond byly do finálního textu disertační práce zahrnuty jen tři nejzásadnější sondy.<sup>83</sup> I přesto

<sup>83</sup> Jako příklady zmiňovaných dalších sond, které nakonec nejsou součástí textu disertační práce, lze uvést např. následující: sonda věnující se typologii e-learningových kurzů na základě v nich použitých online nástrojů a výukových aktivit, sonda zaměřující se na analýzu způsobů, jakými učitelé v kurzech využívají nástroj pro tvorbu online testů a cvičení či sonda mapující využívání online studijních materiálů studenty.

jsou však tyto další (i nedokončené) sondy důležitou součástí disertačního projektu, a to především v tom smyslu, že rozšiřují škálu témat a analytických metod, kterým jsem se v průběhu výzkumu reálně věnoval. A přestože tyto další sondy nejsou v práci podrobněji představovány, znalosti a zkušenosti získané při jejich realizaci se v textu disertační práce odrážejí. Zvláště pak při naplňování metodologických cílů práce.

### 3.2. Zaměření dílčích výzkumných sond

Jak jsem naznačil v předchozí kapitole při popisu výzkumného designu, cílem a zároveň hlavním přínosem paralelních výzkumných sond je možnost přistupovat ke zkoumanému problému z různých směrů. Aby však byl tento cíl skutečně naplněn, bylo nejprve nutné stanovit postup, pomocí kterého by probíhala volba tematického zaměření jednotlivých výzkumných sond. Pro tyto účely jsem si stanovil sadu sedmi kritérií, na základě kterých byla každá zvažovaná výzkumná sonda (resp. její tematické zaměření) posuzována. Preferováno pak bylo vždy takové tematické zaměření, které se v co možná největším množství kritérií lišilo od ostatních sond. Přehled jednotlivých kritérií stejně jako přehled zvolených tematických zaměření realizovaných výzkumných sond nabízí tabulka 5.

Tabulka 5: Přehled kritérií pro volbu tematického zaměření realizovaných výzkumných sond.

Kritéria	Sonda A	Sonda B	Sonda C
<b>Hlavní aspekt učení resp. výuky v LMS</b>	návštěvnost blended kurzů studenty	interakce studentů a učitelů v online diskuzních fórech	proces vyplňování online testů studenty
<b>Hlavní aktér vzdělávacího procesu</b>	student	student i učitel (tutor)	student
<b>Kategorie nástrojů tvůřících LMS (viz kapitola 1.2.2.)</b>	nástroje pro komunikaci a spolupráci, podporu učení i hodnocení	nástroje pro komunikaci a spolupráci	nástroje pro hodnocení
<b>Typ dat – struktura dat (viz kapitola 2.2.1.2.)</b>	tradiční „tabulková“ atribuční data (agregovaná)	data vztahového charakteru, matice sousednosti	data procesního charakteru, logy



<b>Typ dat – granularita dat (viz kapitola 2.2.1.2.)</b>	úroveň studentů	úroveň kurzů	úroveň aktivit studentů v rámci výukové činnosti určitého typu
<b>Analytický přístup a metody analýzy dat (viz kapitola 2.2.1.3.)</b>	predikce, metody klasifikace	sociální analytika učení, analýza sociálních sítí	dolování procesů
<b>Potenciální přínos pro různé zúčastněné strany (viz kapitola 2.2.2.3.)</b>	výzkumník, správce vzdělávacího systému resp. datový analytik	výzkumník, učitel resp. tutor, student	výzkumník, učitel

Prvním kritériem byl obecný aspekt učení resp. výuky v LMS, kterému sonda věnuje pozornost. Učení a výuka v LMS je komplexní proces, při jehož výzkumu se obvykle zaměřuje pozornost pouze na jeden jeho určitý aspekt či jednu jeho určitou část. Základním kritériem tak bylo, aby se každá sonda věnovala jinému aspektu učení či výuky v LMS. Mimo to však bylo dále žádoucí, aby sondy postihovaly co možná nejširší škálu nástrojů, které jsou obsaženy v systémech pro řízení výuky. Při vymezování těchto systémů v kapitole 1.2.2. jsem hovořil o tzv. integrativních vzdělávacích technologiích a nastínil pět základních didaktických oblastí vzdělávacích nástrojů, které jsou součástí každého LMS. Druhým základním kritériem tak bylo to, aby se každá sonda zaměřovala na jinou kategorii nástrojů LMS.

Dalším kritériem byl aktér vzdělávacího procesu, kterému je v rámci výzkumné sondy věnována hlavní pozornost. Podobně jako i samotná oblast analytiky učení a data miningu ve vzdělávání se ve svém disertačním projektu zaměřuji primárně na studenta jakožto aktéra procesu vzdělávání. Mým cílem však bylo věnovat určitou pozornost i učitelům či tutorům, kteří jsou rovněž zcela klíčovými aktéry vzdělávání v prostředí LMS. V sondě B se tak zaměřuji mimo samotné studenty i na vyučující resp. tutorů. Lze také zmínit, že v jedné z realizovaných sond, která se však z důvodu svého rozsahu nakonec nedostala do textu disertační práce, jsem věnoval pozornost výhradně vyučujícím. Konkrétně pak tomu, jakými způsoby ve svých kurzech využívají nástroj pro tvorbu online testů a cvičení.

Z metodologického hlediska bylo důležitým kritériem jednak to, jakému typu dat je v jednotlivých sondách věnována pozornost, jednak dále to, jaký analytický přístup je použit pro analýzu těchto dat. S ohledem na metodologické cíle práce bylo totiž žádoucí využít co možná nejvíce různých analytických metod a technik z oblasti data miningu ve vzdělávání a analytiky učení. To přitom do určité míry souvisí i s typem analyzovaných dat, protože různé typy dat mohou vyžadovat různé způsoby analýzy. V souvislosti s typem dat jsem přitom

využil dvě různá kritéria, konkrétně strukturu dat a granularitu dat (viz výše kapitola 2.2.1.2.). Co se týče zvolených analytických přístupů, resp. metody analýzy dat, bylo mým primárním záměrem věnovat pozornost především exploratorním analytickým technikám. Přesto jsem považoval za vhodné věnovat určitou pozornost i prediktivním metodám, a to především z důvodu jejich poměrně častého využívání v oblasti analytiky učení a data miningu ve vzdělávání.

Posledním a zároveň nejméně důležitým kritériem byl potenciální přínos pro různé zúčastněné strany. Jak jsem popsal v kapitole 2.2.2.3., při praktické aplikaci postupů analytiky učení a data miningu ve vzdělávání může do analytického procesu vstupovat celá řada zúčastněných stran. Stejně tak výstupy tohoto analytického procesu mohou být primárně určeny pro různé aktéry vzdělávacího procesu. V rámci této výzkumně orientované disertační práce, sice nebyla přímo řešena praktická aplikovatelnost, přesto mohou mít jednotlivé realizované sondy určitý přínos pro praxi a případnou aplikaci. A s ohledem na různé zaměření sond může tento přínos směřovat k odlišným zúčastněným stranám. Cílem přitom opět bylo „pokrýt“ v jednotlivých sondách co možná nejvíce různých zúčastněných stran.

### 3.3. Výzkumné otázky

S ohledem na výše nastíněné výzkumné téma a dva základní cíle výzkumu (tj. věcný a metodologický) lze **hlavní výzkumnou otázku** disertačního projektu formulovat následovně: *Jaké poznatky přináší využití metod analytiky učení a data miningu ve vzdělávání pro analýzu učení a výuky v systémech pro řízení výuky?* Jak je přitom z formulace hlavní výzkumné otázky patrné, akcentuji v ní oba výzkumné cíle, které si v této práci kladu. Tzn. zjistit, jakým způsobem probíhá učení a výuka v online systémech typu LMS, a zároveň zmapovat a zhodnotit potenciál analytických metod z oblasti analytiky učení a data miningu ve vzdělávání pro výzkum učení v online prostředí.

Výše uvedená hlavní výzkumná otázka je pak dále konkretizována třemi specifickými výzkumnými otázkami, které se odvíjí od tematického zaměření jednotlivých výzkumných sond. Tři **specifické výzkumné otázky** tohoto disertačního projektu lze tak formulovat následovně:

1. *Jaké jsou možnosti predikce úspěšného absolvování blended kurzů na základě temporálních aspektů návštěvnosti e-learningových opor kurzů v LMS?*
2. *Jak je využitelná metoda analýzy sociálních sítí pro účely zkoumání a rozlišování různých forem interakce studentů a učitelů v online diskuzních fórech v LMS?*
3. *Jak je využitelná metoda dolování procesů pro účely detekování specifických způsobů chování studentů v průběhu plnění online testů v LMS?*

Podobně jako hlavní výzkumná otázka i specifické výzkumné otázky v sobě vždy nesou dvě složky, tj. složku věcnou a složku metodologickou. Tak se první specifická výzkumná otázka meritorně zaměřuje na úspěšnost studentů ve vztahu k temporálním aspektům návštěvnosti blended kurzů, zatímco metodologicky k této problematice přistupuje za využití prediktivních metod. Druhá specifická výzkumná otázka se věcně zaměřuje na komunikaci a interakci studentů a učitelů v online diskuzních fórech, přičemž ji z metodologického hlediska zajímá, nakolik je možné využít analýzu sociálních sítí pro nalezení a rozlišení různých forem interakce. Třetí specifická výzkumná otázka pak zaměřuje pozornost na chování studentů v průběhu plnění online testů a ke zkoumání tohoto problému využívá metodu dolování procesů.

Specifické výzkumné otázky disertačního projektu jako celku jsou zároveň hlavními výzkumnými otázkami jednotlivých výzkumných sond. V kapitolách 4, 5 a 6, které se věnují podrobnému představení výzkumných sond, jsou tyto otázky dále konkretizovány za využití dílčích specifických výzkumných otázek. Pro přehlednost a srozumitelnost však tyto dílčí specifické výzkumné otázky jednotlivých výzkumných sond neuvádím již zde, nýbrž až při popisu samotných sond v odpovídajících kapitolách.

### **3.4. Metody a techniky získávání a analýzy dat**

Co se týče konkrétních postupů při získávání a analýze dat, jsou vždy podrobně popsány v následujících kapitolách při popisu metodologie jednotlivých sond. Přesto považuji za vhodné již nyní alespoň v krátkosti naznačit obecný postup, který byl aplikován při realizaci všech výzkumných sond. Zároveň je nutné explicitně upozornit, že získávání, transformace, a především analýza dat byly v rámci této disertační práce i samotným zkoumaným problémem, vzhledem ke stanoveným metodologickým cílům práce. I proto je této problematice v práci věnována zvýšená pozornost a rovněž v závěrečné diskuzi jsou metodologické otázky explicitně řešeny.

Jak bylo uvedeno již v úvodu, všechna data analyzovaná v této disertační práci pocházejí z online výukového systému Moodle provozovaného na Filozofické fakultě Masarykovy univerzity, kde je instalace tohoto systému známá pod označením ELF. Pro analýzu dat přitom byla využívána jen taková data, která jsou standardně uchovávána v základní instalaci systému Moodle (tj. nebyl například využit žádný rozšiřující nástroj pro sběr doplňujících dat). Hlavním důvodem bylo to, aby realizované analýzy mohly být replikovatelné i na jiných instalacích systému Moodle, a to bez nutnosti instalovat doplňující nástroje a zajišťovat sběr dalších specifických dat.

Samotné **získávání dat** spočívalo v extrakci dat z databáze systému Moodle. Ta přitom ve výchozí podobě sestává z několika stovek tabulek<sup>84</sup>, čili nezbytnou součástí získávání dat bylo nejprve podrobné seznámení se se strukturou databáze systému Moodle a s obsahem jednotlivých tabulek. Poté musely být v rámci každé sondy identifikovány všechny tabulky, které bylo třeba využít pro získání potřebných dat. Následovala formulace databázového dotazu, který zajistil extrakci potřebných dat z databáze. Databázový dotaz byl formulován pomocí jazyka SQL (*structured query language*), který je běžně používán v databázích tohoto typu (tj. relační databáze). Jednotlivé databázové dotazy přitom byly relativně komplexní, jelikož pracovaly s množstvím údajů napříč různými tabulkami a musely kombinovat řadu dílčích podmínek. Před samotnou analýzou pak ve všech případech docházelo k tomu, že data musela být dále transformována, aby bylo možné aplikovat odpovídající analytickou techniku. K těmto úpravám dat docházelo již za využití externího analytického nástroje. V průběhu získávání a transformace dat zároveň docházelo k jejich anonymizaci (viz následující kapitola 3.5. *Etické aspekty výzkumu*).

Transformace a následná **analýza dat** probíhaly primárně ve statistickém prostředí *R* (R Core Team, 2018), resp. za využití integrovaného vývojového prostředí *RStudio* (RStudio Team, 2016). Pro účely samotných analýz pak bylo využito několika specializovaných doplňkových knihoven, zvláště pak následující: *caret* (Kuhn M. , 2018), *igraph* (Csárdi & Nepusz, 2006), *randomForest* (Liaw & Wiener, 2002), *ROCR* (Sing, Sander, Beerewinkel, & Lengauer, 2005), *rpart* (Therneau & Atkinson, 2018). Mimo prostředí *R* resp. *RStudio* pak byly v rámci analýz využity rovněž analytické nástroje *Weka* (Frank, Hall, & Witten, 2016), *Gephi* (Bastian, Heymann, & Jacomy, 2009), *ProM* (van Dongen, de Medeiros, Verbeek, Weijters, & van der Aalst, 2005) a *Disco* (Disco, 2019).

### 3.5. Etické aspekty výzkumu

Považuji za nezbytné se alespoň v krátkosti dotknout etických aspektů realizovaného disertačního projektu. Jak jsem naznačil v kapitole 2.3.7., etická dimenze analytiky učení a data miningu ve vzdělávání je jednou z hlavních oblastí, kterým je věnována pozornost. Zároveň jde však o oblast, která je stále živě diskutována a ve které neexistuje jeden všeobecně přijímaný etický kodex či obecně postup, jak eticky provádět pedagogický výzkum založený

---

<sup>84</sup> Množství tabulek se samozřejmě mění v závislosti na tom, o jakou verzi systému Moodle jde, a dále také podle toho, nakolik jsou používány další rozšiřující nástroje, které v databázi systému vytváří další tabulky pro vlastní fungování. Základní verze Moodle má v současnosti (tj. verze 3.7) ve své databázi přibližně 400 tabulek. Moodle na FF MU (tj. systém ELF) je starší verze, ale zároveň má několik rozšíření oproti základní instalaci, proto obsahuje tabulek ještě o několik desítek více.

na metodách analytiky učení a data miningu ve vzdělávání. Rovněž na lokální úrovni Filozofické Fakulty Masarykovy univerzity, kde byla disertační práce realizována, neexistuje prozatím zavedená a explicitně popsaná praxe zohledňující specifika výzkumu vycházejícího z oblastí data miningu ve vzdělávání a analytiky učení.

Z výše uvedených důvodů jsem proto v rámci svého výzkumu přistoupil ke dvěma základním krokům s ohledem na jeho etické aspekty. V prvním kroku mi jako výchozí bod sloužil návrh etického kodexu české pedagogické vědy a výzkumu, jak jej prezentují Průcha a Švaříček (2009). V druhém kroku jsem si pro účely realizovaného výzkumu stanovil další doplňující principy a pravidla, která specifikovala dílčí výzkumné postupy, respektive kladla na mě samotného jakožto realizátora výzkumu další doplňující požadavky, zvláště co se týče anonymity a způsobu nakládání s daty. S ohledem na specifika realizovaného výzkumu a chybějící zavedenou praxi analytiky učení či data miningu ve vzdělávání se totiž jeví jako vhodná strategie stanovit raději přísnější etické principy či postupy. V této disertační práci tudíž respektuji ještě následující principy a pravidla:

1. K důsledné anonymizaci dochází nejen na úrovni jedince (studenta, učitele apod.), ale také na všech dalších relevantních úrovních (název kurzu, název konkrétní studijní či výukové aktivity v kurzu apod.).
2. Vždy, když to situace dovoluje, jsou data anonymizovaná i vůči samotnému výzkumníkovi, který výzkum realizuje. Tj. ani sám výzkumník neví o jaké studenty či kurzy se jedná. To je zajišťováno v průběhu získávání dat z LMS a jejich transformace pro účely následné analýzy. V rámci tohoto procesu dochází k nahrazení všech používaných identifikátorů studentů, kurzů, aktivit v kurzech apod. jiným náhodně zvoleným identifikátorem. Při samotné analýze dat tak již není ani technicky možné zpětně získat původní identifikátor studenta či kurzu.
3. V žádné z realizovaných výzkumných sond nejsou využívána resp. analyzována data z aktuálně běžících kurzů. Vždy jsou využívána pouze data archivní, tzn. data z dřívějších běhů kurzu.
4. V návaznosti na předchozí bod pak dále platí, že v žádné z realizovaných výzkumných sond nepřistupuji k takovému typu šetření, které by mělo přímý vliv na studenty či jejich studium<sup>85</sup>. To mimo jiné znamená, že dílčí výsledky analýz nebyly přímo využity pro žádné jiné účely než pro účely výzkumu v rámci řešení

---

<sup>85</sup> Zde jde především o to, že záměrně volím pouze takové výzkumné přístupy, jejichž součástí není zásah do edukační reality např. v podobě upozorňování či varování studentů či vyučujících, adaptace výukového obsahu apod. (viz 2.2.2.2. *Proces analytiky učení*).

disertačního projektu. Zároveň k nim neměla přístup žádná z případných dalších zúčastněných stran než samotný autor výzkumu a této práce.

### 3.6. Limity zvoleného výzkumného postupu

Zvolený výzkumný postup s sebou samozřejmě nese i určité limity. Ty jsou přitom dány již samotným pojetím disertační práce, která se zaměřuje primárně na exploratorní analytické techniky. V rámci celé práce se tak pohybuji na úrovni deskripce a explorace a neusiluji o konfirmaci určitých předpokladů či hypotéz. Věřím, že oblasti analytiky učení a data miningu ve vzdělávání jsou stále relativně mladé, a proto je vhodnější a přínosnější věnovat pozornost spíše důkladné exploraci než konfirmaci.

S výše uvedeným se zároveň pojí nemožnost zobecnění. Jelikož se zaměřuji primárně na exploraci a jelikož pro analýzu využívám pouze data ze systému Moodle na Filozofické fakultě Masarykovy univerzity, není možné zjištěné výsledky zobecňovat nad rámec případů zkoumaných v jednotlivých sondách. Na druhou stranu jsem ve všech sondách usiloval o to, aby analyzovaná data pocházela z poměrně širokého a různorodého spektra kurzů. To by mělo vést k tomu, že například podobné formy interakce v diskuzních fórech (viz Sonda B) či podobné typy chování studentů v průběhu plnění online testů (viz Sonda C) budou nalezitelné i v kurzech a testech realizovaných v LMS Moodle na jiných univerzitách, je-li kontext a způsob využívání LMS dostatečně podobný.

V neposlední řadě jsem se v disertační práci záměrně omezoval pouze na využití dat z databáze LMS Moodle. Toto omezení je však nepochybně limitem s ohledem na co možná nejkomplexnější porozumění zkoumanému problému. Nutně totiž vede k omezení pozornosti pouze na určité aspekty zkoumaného problému, a to navíc jen na takové, které jsou alespoň potenciálně zachytitelné skrze automatizovaný sběr dat o chování uživatelů v online prostředí. Nutně ale stále zůstává řada aspektů souvisejících s učením a výukou v LMS, které nejsou těmito postupy zachytitelné<sup>86</sup>. Lze proto předpokládat, že pro hlubší porozumění zkoumanému problému by bylo nutné kombinovat použité analytické postupy s dalšími výzkumnými metodami a technikami. Jako zvláště slibná se pak jeví kombinace s kvalitativně

---

<sup>86</sup> Jako názorný příklad může posloužit situace, kdy je např. nějaký rozsáhlejší studijní materiál v kurzu vytvořen takovým způsobem, že se celý zobrazuje pouze na jedné ze stránek kurzu. V takovém případě může student trávit i několik hodin tím, že s daným studijním materiálem pracuje, ovšem o této práci nebude v automaticky zaznamenaných datech žádná informace, protože zde nedochází k přechodu z jedné stránky na jinou. Jiným příkladem mohou být takové studijní materiály, se kterými studenti nepracují přímo v online kurzu, nýbrž si je stáhnou do svého vlastního počítače. V takovém případě pak opět nelze pomocí automatizovaného sběru dat v LMS nijak zjistit, jakým způsobem studenti s daným materiálem pracují.

orientovanými výzkumnými postupy, které by umožnily věnovat pozornost nejen kvantifikovatelným aspektům učení a výuky v LMS, ale také takovým aspektům, jež souvisí se subjektivním vnímáním jednotlivých zúčastněných aktérů.





## 4. Sonda A - Analýza možností vybraných klasifikačních algoritmů pro účely predikce úspěšnosti studentů v blended kurzech

Jak bylo naznačeno v kapitole 2.3.2. *Predikce úspěšnosti a identifikace rizikových studentů*, problematika predikce úspěšnosti studentů je v data miningu ve vzdělávání a v analytice učení jednou z hlavních oblastí zájmu výzkumníků. Podobně lze toto téma považovat za poměrně tradiční i v kontextu e-learningu jako takového, kde byly již od samotných počátků využívání moderních technologií ve vzdělávání zároveň kladeny otázky na to, zda a případně nakolik využívání těchto technologií přispívá k úspěšnosti studentů (srov. Dawson, Gašević, Siemens, & Joksimović, 2014; Romero & Ventura, 2013). Data mining ve vzdělávání a analytika učení jakožto výzkumné oblasti na toto obecnější téma pak více méně navazují, ovšem s jedním zásadním rozdílem. Kladou větší důraz na samotnou predikci (ideálně pak dostatečně včasnou predikci), pro kterou se přitom snaží využít především data o chování studentů v online vzdělávacích prostředích (Gašević, Dawson, Rogers, & Gasevic, 2016).

S důrazem na analýzu chování studentů v online vzdělávacích prostředích pak souvisí i to, že je v kontextu systémů pro řízení výuky (LMS) směřována hlavní pozornost na online learning a online kurzy. Naopak spíše ojediněle jsou realizovány výzkumy zaměřující se na predikování úspěšnosti studentů v kontextu blended learningu resp. kurzů, které neprobíhají výhradně v online prostředí, nýbrž kombinují vzdělávání v online prostředí se vzděláváním skrze tradiční (off-line) výuku (např. AlJarrah, Thomas, & Shehab, 2018; Gitinabard, Xu, Heckman, Barnes, & Lynch, 2019; González Nespereira, Dai, Díaz Redondo, & Fernández Vilas, 2014; González Nespereira, Fernández Vilas, & Díaz Redondo, 2015). Zaměření pozornosti právě na online kurzy přitom není nijak zvlášť překvapivé. V rámci online kurzů totiž veškerá výuková aktivita probíhá v online vzdělávacím prostředí, a tudíž data o chování studentů v tomto prostředí zachycují mnohem komplexnější obraz o průběhu výuky, resp. vzdělávání jako celku. Naopak v případě blended learningu probíhá v online prostředí pouze větší či menší část výuky, a tudíž je možné skrze analýzu dat o chování studentů v online prostředí získat vždy pouze dílčí obraz o výuce jako celku. Na druhou stranu však blended learning sehraává v současnosti poměrně velkou roli. Například v kontextu univerzit a vysokých škol, kde se zároveň v současnosti problematika data miningu a analytiky učení rozvíjí asi nejvíce, a zvláště pak v souvislosti s využíváním LMS v rámci univerzitní výuky, je blended learning zastoupen výrazně více než online learning (Švaříček & Zounek, 2008).

V souvislosti s predikcí úspěšnosti studentů se v analytice učení a data miningu ve vzdělávání využívá řada různých analytických metod (viz kapitola 2.2.1.3.1. *Prediktivní metody*). Hlavní snahy přitom směřují především k využití pokročilých a v tradičním pedagogickém výzkumu ojediněle využívaných prediktivních technik jako např. rozhodovací stromy, náhodný les, podpůrné vektory, umělé neuronové sítě apod. Zatím však stále zůstává otázkou, zda je využití těchto „nových“ analytických metod skutečně výrazným přínosem v oblasti predikce úspěšnosti studentů. Případně pak, které z široké škály dostupných prediktivních metod a technik dávají v tomto kontextu nejlepší výsledky. Prozatím téměř neřešenou otázkou je pak to, nakolik jsou tyto metody využitelné přímo v kontextu blended learningu.

V návaznosti na obecnou otázku po možnostech predikce úspěšnosti studentů, a to jak v kontextu online learningu, tak i v souvislosti s blended learningem, se pak nabízí několik doplňujících či rozšiřujících otázek. V rámci analytiky učení a data miningu ve vzdělávání se jeví jako důležité především následující dvě otázky. První se ptá na konkrétní indikátory či ukazatele, které jsou využitelné jako prediktory úspěšnosti studentů. V dosavadním výzkumu se přitom jako prediktory úspěšnosti využívají především ukazatele jako: celkový čas strávený v LMS, míra aktivity v LMS, frekvence návštěv v LMS apod. (srov. AlJarrah, Thomas, & Shehab, 2018; Jo, Kim, & Yoon, 2015; González Nespereira, Dai, Díaz Redondo, & Fernández Vilas, 2014; You, 2016). Druhá otázka, která je akcentována především v posledních letech, se týká zobecnitelnosti a přenositelnosti dosavadních výsledků napříč různými kurzy či dokonce napříč různými online vzdělávacími systémy. Konkrétně jde především o to, nakolik a s jakou prediktivní silou jsou výše uvedené prediktivní metody a zmíněné prediktory úspěšnosti aplikovatelné nejen v rámci jednoho konkrétního kurzu, ale také obecně napříč různými kurzy (srov. Gašević, Dawson, Rogers, & Gasevic, 2016; Gitinabard, Xu, Heckman, Barnes, & Lynch, 2019; Huang, Lu, Huang, Yin, & Yang, 2019).

Tato výzkumná sonda proto věnuje pozornost právě výše naznačeným otázkám a problémům. Oproti většině dosavadního výzkumu v této oblasti se však zaměřuje na blended learning a úspěšnost studentů v blended kurzech. V kontextu blended learningu pak srovnává několik prediktivních technik a jejich predikční schopnosti. Pro predikci úspěšnosti studentů jsou přitom využity různé temporální indikátory návštěvnosti e-learningových opor blended kurzů a je provedeno posouzení přínosu jednotlivých prediktorů. V neposlední řadě pak sonda A usiluje o zhodnocení toho, nakolik jsou srovnávané prediktivní techniky a použité prediktory generalizovatelné a použitelné při predikci úspěšnosti studentů napříč různými blended kurzy.

## 4.1. Přehled dosavadních výzkumů k sondě A

Romero a Ventura (2019) zmiňují v editorialech ke speciálnímu číslu zaměřenému na tuto problematiku, že predikce výkonu či úspěšnosti studentů je jedním z nejstarších a nejvíce studovaných problémů v kontextu analytiky učení a data miningu ve vzdělávání. Napříč realizovanými výzkumy jsou pak s větší či menší úspěšností využívány různé regresní či klasifikační prediktivní techniky, přičemž často dochází i k praktickému využití získaných prediktivních modelů, a to především v rámci systémů včasného varování (EWS), jejichž cílem je co možná nejvčasnější identifikace studentů, kteří mohou mít problém s dokončením kurzu (viz Romero & Ventura, 2013). Řada výzkumů v této oblasti se zaměřuje na využití dat ze systémů typu LMS, kterým věnuje pozornost i tato disertační práce, případně věnují pozornost datům ze studentských informačních systémů (SIS) či kombinaci dat z LMS i SIS (srov. Gašević, Dawson, Rogers, & Gasevic, 2016). Výrazným impulzem pro výzkum v této oblasti bylo rovněž značné rozšíření kurzů typu MOOC, ke kterému došlo především v průběhu roku 2012 a letech následujících, a které vedlo k dalšímu prohloubení zájmu o problematiku predikce úspěšnosti studentů, zvláště pak v kurzech tohoto typu. Jak ale upozorňují Gitinabardová et al. (2019), přestože existuje relativně extenzivní výzkum predikce úspěšnosti v MOOC či obecně online kurzech, co se týče blended kurzů, jsme stále relativně na počátku. Predikce úspěšnosti studentů v blended kurzech je tak zatím velmi omezená, jen obtížně se daří dosáhnout dostatečně včasné a zároveň přesné predikce, není zatím zřejmé, jaké indikátory jsou nejlepšími prediktory úspěšnosti, a dosavadní modely často nebývají použitelné u jiných kurzů, než na kterých byly vytvořeny.

V této přehledové části nejprve mapují dosavadní snahy výzkumníků o predikci úspěšnosti studentů v blended kurzech v rámci systémů pro řízení výuky (LMS). Následně se zaměřují na temporální charakteristiky návštěvnosti jakožto jedny z nejvíce využívaných prediktorů úspěšnosti v online kurzech. Zároveň první výzkumy zaměřující se na tento typ prediktorů v kontextu online learningu naznačují potenciál k využití těchto prediktorů i při predikci úspěšnosti v blended kurzech (viz např. Jo, Park, Kim, & Song, 2014; Yu & Jo, 2014). Závěrečnou podkapitolu věnují problematice zobecnitelnosti či přenositelnosti prediktivních modelů, kterou lze považovat za jedno z neaktuálnějších témat současného výzkumu v této oblasti (srov. Romero & Ventura, 2019).

### 4.1.1. Predikce úspěšnosti studentů v kontextu blended learningu a LMS

Zaměříme-li se s ohledem na omezený prostor pouze na zdroje z posledních deseti let, lze mezi prvními zmínit exploratorní studii Macfadyena a Dawsona (2010), kteří zkoumali

možnosti využití dat z LMS (konkrétně systém *Blackboard*) pro účely vývoje systému včasného varování (EWS). Analyzovaná data pocházela z pěti různých kurzů, ovšem ve všech případech šlo o online kurzy. Romero a kol. (viz Romero, Espejo, Zafra, Romero, & Ventura, 2013; Romero, López, Luna, & Ventura, 2013) se již zaměřují přímo na LMS Moodle a zároveň provádějí srovnání různých klasifikačních metod a algoritmů. Bohužel však explicitně nespecifikují, zda data pocházejí z online kurzů či blended kurzů, nýbrž hovoří spíše technicistně o „Moodle kurzech“. Naopak Agudo-Peregrina et al. (2014) se již zaměřují explicitně i na blended kurzy, když vedle dat ze šesti online kurzů analyzují rovněž data ze dvou blended kurzů. Analyzovaná data pocházejí opět z LMS Moodle, ovšem autoři již záměrně usilují o to, aby byl jejich postup přenositelný, resp. nezávislý na konkrétním systému, a proto se zaměřují spíše na obecné typy interakce v LMS<sup>87</sup>. Konkrétně navazují na Moorovu (1989) typologii interakcí a rozlišují tři základní typy interakcí v LMS: interakce mezi studenty navzájem, interakce mezi studentem a učitelem a interakce mezi studentem a obsahem. Výsledky však naznačují, že ačkoli má tento přístup určitý potenciál v kontextu online kurzů, v případě blended kurzů se zdá být neplodný. Autoři nenacházejí žádný vztah mezi četnostmi jednotlivých typů interakcí v LMS a výsledky studentů v blended kurzech. Zároveň sami upozorňují na možnost, že je využití tohoto typu dat pro účely predikce úspěšnosti použitelné pouze u online kurzů, resp. že v případě blended kurzů je zřejmě nutné využít pokročilejší metody a nástroje analýzy či jiné přístupy k řešení predikce.

Přímo na blended kurzy se pak v souvislosti s predikcí úspěšnosti zaměřují např. Jo, Park, Kim a Song (2014) či Yu a Jo (2014). V obou případech je věnována pozornost především proměnným, které se týkají návštěvnosti kurzů a míry interakce studentů v nich. I přes určitou slibnost výsledků však obě studie trpí velmi malým množstvím dat, a to jak co se týče počtu studentů tak i počtu sledovaných kurzů. Na včasnou predikci úspěšnosti studentů v blended kurzech v rámci LMS se dále zaměřili Sheshadri et al. (2018), kteří se opět věnují především temporálním charakteristikám návštěvnosti jakožto potenciálním prediktorům. Analýzy jsou však prováděny na studentech pouze tří různých kurzů (resp. dvou běžích téhož kurzu a jednoho jiného kurzu). Lu et al. (2018) pak věnují pozornost pouze jedinému blended kurzu, mezi prediktory však používají i proměnné týkající se výuky mimo LMS (např. výsledky průběžných „papírových“ testů či účast na doplňující výuce). Poměrně nepřekvapivě pak autoři uzavírají, že využití jak proměnných týkajících se online prostředí, tak proměnných týkajících se tradičního (off-line) prostředí přináší lepší výsledky. Určitý příspěvek k predikci

---

<sup>87</sup> Autoři v rámci studie používají primárně pojem *virtuální vzdělávací prostředí* (VLE), ovšem využívají ho ve stejném smyslu, v jakém je používán pojem LMS v této práci.

úspěšnosti studentů v blended kurzech pak nacházíme i v českém pedagogickém prostředí, kde se této problematice věnovala Vaculíková (2018) v souvislosti se seberegulovaným učením (SRL). Bohužel se však studie zaměřuje pouze na 54 studentů jednoho konkrétního kurzu, což zjištěné výsledky výrazně limituje, co se týče zobecnění.

Z hlediska nejčastěji využívaných prediktorů úspěšnosti můžeme učinit několik základních rozlišení. Jak již bylo naznačeno výše, vedle dat z LMS jsou v některých studiích (např. Estacio & Raga, 2017; Gašević, Dawson, Rogers, & Gasevic, 2016) využívány rovněž data o studentech pocházející ze studentských informačních systémů (SIS) či jiných systémů spíše administrativního než výukového charakteru. Typicky přitom jde o data demografického či popisného charakteru (pohlaví, občanství, bydliště, semestr studia apod.) anebo o data o předchozí studijní úspěšnosti (výsledky na střední škole, výsledky přijímacího řízení, výsledky v dosavadních kurzech na vysoké škole apod.). Existují rovněž pokusy o alespoň částečné zachycení off-line stránky blended learningu, kterou pochopitelně systémy typu LMS nezachytí. Příklad takové studie nabízejí již zmiňovaní Lu et al. (2018). V principu si lze ale představit i další proměnné, které by bylo možné v této souvislosti využít (např. docházka na prezenční výuku, aktivita na prezenční výuce, četnost osobních konzultací s vyučujícím apod.). Co se týče dat pocházejících z LMS, můžeme v dosavadních studiích odlišit tři základní skupiny nejčastěji využívaných prediktorů.

První skupinu tvoří **obecné temporální charakteristiky návštěvnosti kurzů**, kterým se podrobněji věnuje následující část. Jde o různé míry toho, jak moc je kurz navštěvován, přičemž obecnost v tomto kontextu znamená, že jde o návštěvnost kurzu jako celku a nerozlišuje se tak např. aktivita studentů v obsahově různých částech kurzu. Temporalita či časovost pak odkazuje k tomu, že jde o metriky návštěvnosti, které se v nějakém ohledu vážou na čas, např. kdy k návštěvám dochází, jak pravidelně apod. (srov. AlJarrah, Thomas, & Shehab, 2018; Jo, Park, Kim, & Song, 2014; Jo, Kim, & Yoon, 2015; You, 2016; Yu & Jo, 2014).

Druhou skupinu tvoří obvykle poměrně jednoduché **četnostní metriky aktivity studentů ve specifických oblastech kurzu**. Typicky jde o prostý součet záznamů o aktivitě studenta (tj. logy) v rámci konkrétního nástroje v LMS, jako jsou například nástroje pro tvorbu testů, nástroje pro prezentaci studijních materiálů, nástroje pro odevzdávání úkolů apod. (srov. Estacio & Raga, 2017; Gašević, Dawson, Rogers, & Gasevic, 2016; Lu, Huang, Lin, Ogata, & Yang, 2018; Sheshadri, Gitinabard, Lynch, Barnes, & Heckman, 2018; Vaculíková, 2018). Určitou nevýhodou prediktorů tohoto typu je však přímá vazba na konkrétní LMS (např. Moodle), a tudíž horší možnosti přenositelnosti takových řešení mezi různými LMS.

Třetí skupinu tvoří různé **metriky spojené s aktivitou studentů v diskuzních fórech**. Mezi používanými metrikami pak najdeme jednak jednoduché četnostní charakteristiky jako počet vytvořených diskuzních příspěvků, počet odpovědí na příspěvky ostatních studentů apod. (viz např. Macfadyen & Dawson, 2010; Romero, López, Luna, & Ventura, 2013; Yu & Jo, 2014), jednak i pokročilejší metriky vycházející z analýzy sociálních sítí (SNA) jako např. různé míry centrality jednotlivých aktérů v síti<sup>88</sup> (Gitinabard, Xu, Heckman, Barnes, & Lynch, 2019; Joksimović et al., 2016).

Nutno zároveň dodat, že samozřejmě existují i takové studie, které využívají specifické typy prediktorů nespádajících do žádné z výše nastíněných skupin. Ty jsou však z hlediska četnosti zastoupeny výrazně méně. Např. zmiňovaná studie Vaculíkové (2018) využívá rovněž data z dotazníku na seberegulované učení. Jiným příkladem jsou Nakayama, Mutsuura a Yamamoto (2017), kteří využívají specifické míry toho, nakolik si studenti v průběhu kurzu píší průběžné studijní poznámky.

Co se pak týče používaných prediktivních metod, asi nejčastěji využívané zatím zůstávají lineární a logistická regrese, a to v závislosti na typu predikované proměnné (viz např. Gašević, Dawson, Rogers, & Gasevic, 2016; Jo, Park, Kim, & Song, 2014; Macfadyen & Dawson, 2010; Vaculíková, 2018). Řada autorů však využívá i jiné typy prediktivních metod a klasifikačních algoritmů, případně v rámci jedné studie využívá několik algoritmů a nabízí jejich srovnání. Tak např. Sheshadri et al. (2018) srovnávají výsledky logistické regrese s algoritmem *k*-nejbližších sousedů (*k-nearest neighbors* – *k-NN*) a s algoritmem z rodiny rozhodovacích stromů. Někteří autoři pak přistupují ke srovnávání algoritmů velmi zevrubně a srovnávají až 15 (Zafra, Romero, & Ventura, 2011), 20 (Romero, López, Luna, & Ventura, 2013) či dokonce více jak 20 různých algoritmů (Romero, Espejo, Zafra, Romero, & Ventura, 2013). Z hlediska typu přitom jde nejčastěji a algoritmy založené na rozhodovacích stromech, algoritmy založené na pravidlech, algoritmy z rodiny bayesovských klasifikátorů či algoritmy založené na umělých neuronových sítích. Srovnávání jednotlivých prediktivních postupů však alespoň prozatím (a v kontextu blended learningu obzvláště) nedává jednoznačnou odpověď ohledně jejich prediktivních schopností. Do značné míry je to však zřejmě způsobeno tím, že srovnávání jednotlivých algoritmů zatím probíhá buď pouze na datech z jednoho kurzu, případně na poměrně malém množství kurzů (v řádu jednotek).

---

<sup>88</sup> Co se týče měr centrality aktérů v síti, jde např. o stupeň (*degree*), blízkost (*closeness*), mezilehlost (*betweenness*) apod.

#### **4.1.2. Temporální charakteristiky návštěvnosti jako prediktory úspěšnosti**

Jak bylo řečeno výše, jednou z nejčastěji využívaných skupin prediktorů úspěšnosti studentů v blended (ale i online) kurzech jsou temporální charakteristiky návštěvnosti. Jde o proměnné, které se nějakým způsobem dotýkají časovosti navštěvování kurzu studenty, a zároveň se zaměřují na kurz a jeho návštěvnost jako celek, spíše než by se týkaly dílčích výukových aktivit v kurzu. V oblasti data miningu ve vzdělávání a analytiky učení jsou pak výzkumy využívající tento typ prediktorů úspěšnosti studentů teoreticky a věcně ukotvovány nejčastěji v kontextu seberegulovaného učení (viz např. Pintrich, 2004; Pintrich, Smith, Garcia, & McKeachie, 1993; Winne, 2010; Zimmerman & Martinez-Pons, 1988) a zvláště v těch aspektech seberegulovaného učení, které se týkají plánování a time managementu (srov. AlJarrah, Thomas, & Shehab, 2018; Jo, Kim, & Yoon, 2015; Kim, Park, Yoon, & Jo, 2016; Kim, Yoon, Jo, & Branch, 2018; You, 2016). Dosavadní výzkum v oblasti e-learningu totiž naznačuje, že právě seberegulace a volba odpovídajících učebních strategií je jedním z důležitých faktorů úspěchu v online ale i blended kurzech (Broadbent, 2017; You, 2016).

Podle některých autorů (např. Hadwin, Nesbit, Jamieson-Noel, Code, & Winne, 2007; You, 2016) však jednoduché souhrnné počty záznamů o aktivitě studentů v kurzu (tj. logy) vypovídají jen naprosté minimum (pokud vůbec něco) o jejich učebních strategiích, plánování, organizaci času apod. Proto se řada autorů zaměřuje na hledání sofistikovanějších metrik a proxy indikátorů, které by více vypovídaly o výše uvedených obecných konceptech. Někteří autoři (např. AlJarrah, Thomas, & Shehab, 2018) tak místo celkových počtů logů pracují s počtem logů za určitou časovou jednotku (např. týden, den, první polovina kurzu apod.), což už může poskytovat doplňující informace o tom, jestli jsou např. studenti v kurzu aktivní od samotného začátku, případně o tom, jak se jejich aktivita v čase vyvíjí. González Nespereira et al. (2014; 2015) pak jdou v průzkumu tohoto přístupu ještě o krok dál a za využití analýzy časových řad a dekompozice dílčích trendů jsou schopni odlišit různou míru aktivity a její vývoj v průběhu konání kurzu mezi úspěšnými a neúspěšnými studenty.

Řada autorů (např. Jo, Park, Kim, & Song, 2014; Sheshadri, Gitinabard, Lynch, Barnes, & Heckman, 2018; Yu & Jo, 2014) místo počtu logů využívá počet návštěv resp. počet přihlášení do kurzu, případně využívají jak počet jednotlivých logů, tak i počet návštěv. To opět může poskytovat podrobnější obrázek o aktivitě studentů v kurzu, jelikož stejné množství záznamů o aktivitě může být na jedné straně rozděleno do pěti různých návštěv, zatímco na druhé straně může proběhnout v jediné návštěvě. Počet návštěv tak více vypovídá o tom, jak moc či jak často studenti skutečně „přichází“ do určitého kurzu, přičemž některé výsledky

naznačují, že četnost návštěv je významným prediktorem úspěchu v kurzu (např. You, 2016). Na druhou stranu, výzkumným problémem o sobě zůstává vymezení toho, co je to vlastně návštěva kurzu, resp. identifikace jednotlivých návštěv. V online prostředí obecně a stejně tak v systémech typu LMS totiž uživatelé obvykle nijak explicitně neukončují svoji návštěvu (tj. např. neklikají na tlačítko pro odhlášení ze systému), a tudíž je vždy nutné nějakým způsobem odvozovat, kdy jednotlivé návštěvy kurzu skutečně končí (srov. Jo, Kim, & Yoon, 2015; Kim, Park, Yoon, & Jo, 2016).

Relativně dlouhou dobu je rovněž věnována výzkumná pozornost celkovému množství času stráveného v kurzu či při řešení určitého úkolu (tzv. *time-on-task*), jak ukazují Kovanović et al. (2015a, 2015b). Podobně jako v případě počtu návštěv však nejde o triviální problém, nýbrž se vždy musí přistupovat k určité formě odhadu na základě dostupných dat. V kontextu predikce úspěšnosti studentů v online či blended kurzech v LMS se nejčastěji pracuje s celkovým množstvím času, který student stráví prací v kurzu. Dosavadní výsledky využití celkového času stráveného v kurzu pro predikci úspěšnosti však nedávají jednoznačnou odpověď. Výsledky autorů Yu a Jo (2014) naznačují, že celkový čas strávený v kurzu může být důležitým prediktorem. Dle výsledků Joa et al. (2014) však může záležet na typu či formě kurzu. Zatímco v kurzu založeném na komunikaci v online diskuzních fórech byl celkový čas druhým nejsilnějším prediktorem úspěšnosti, v případě kurzu založeném na zpřístupňování studijních materiálů a plnění průběžných úkolů nehrál celkový čas strávený v kurzu vesměs žádnou roli. V novějším výzkumu Kima et al. (2018) se navíc již celkový čas strávený v kurzu ukazuje jako nevýznamný z hlediska predikce úspěšnosti.

Poměrně často je věnována pozornost i pravidelnosti (resp. nepravidelnosti) s jakou studenti přistupují do kurzu v LMS. Podle řady autorů (např. Kim, Yoon, Jo, & Branch, 2018; You, 2016; Yu & Jo, 2014) jde totiž o jeden z velmi důležitých prediktorů úspěšnosti studentů, a to jak v online kurzech tak i v blended kurzech. Jak ale naznačují Jo et al. (2014), může opět záležet na tom, o jaký kurz jde. Oproti celkovému času strávenému v LMS se totiž pravidelnost přístupů zdá být důležitá spíše v kurzech nediskuzního charakteru. Mimo výše uvedené temporální charakteristiky se pak v některých výzkumech věnuje pozornost i dalším ukazatelům, případně kombinacím jednotlivých ukazatelů. Například Miyamoto et al. (2015) se zaměřili na tzv. „spacing effect“<sup>89</sup> a poukázali na důležitý vztah mezi celkovým časem stráveným v kurzu a počtem návštěv v kurzu. Konkrétně zjistili, že mezi studenty, kteří stráví

---

<sup>89</sup> Jedná se o jev zdokumentovaný již Ebbinghausem (1885) při výzkumu paměti. Obecně jde o to, že tzv. rozložené učení, kdy k učení dochází po menších částech a s průběžným opakováním, je z hlediska retence učební látky lepší, než učení tzv. nakupené, kdy se student učí jednorázově velké množství obsahu.



v kurzu stejné množství času, dosahují lepších výsledků ti, kteří navštíví kurz vícekrát (tj. čas strávený v kurzu mají rozložený do více návštěv). Především to pak platí pro ty studenty, kteří celkově tráví v kurzech méně času.

### **4.1.3. Otázky zobecnitelnosti a přenositelnosti prediktivních modelů**

I přes to, že byl výše představen určitý rozvoj v oblasti predikce úspěšnosti studentů v kontextu blended kurzů, je nutné jedním dechem dodat, že je výzkum této problematiky stále do značné míry v počátcích. Vesměs všechny výše citované studie totiž trpí výraznými nedostatky, co se týče otázek zobecnitelnosti a přenositelnosti zjištěných výsledků, jelikož využívají data z jednoho či pouze několika málo různých kurzů. Ostatně v celé oblasti analytiky učení a data miningu ve vzdělávání se téma zobecnitelnosti a přenositelnosti dostává do popředí teprve v posledních letech. Jak uvádějí Gašević, Dawson a Siemens (2015), přestože byla věnována určitá pozornost identifikaci hlavních indikátorů úspěšnosti studentů, existuje zcela zásadní nedostatek studií, které by usilovaly o zhodnocení dopadu a přenositelnosti výsledků této počáteční práce napříč různými doménami a kontexty. A to se netýká jen blended kurzů, ale problematiky predikce úspěšnosti studentů v online kurzech obecně. Nedostatek studií tohoto typu přitom přetrvává dodnes, a to i přesto, že je toto téma v kontextu predikce úspěšnosti obecně považováno za jedno z nejdůležitějších (srov. Romero & Ventura, 2019). Navíc i studie, které se výslovně zaměřují na otázky zobecnitelnosti prediktivních modelů, využívají data z poměrně malého množství kurzů. Např. aktuální studie Gitinabardové et al. (2019) věnující se zobecnitelnosti přímo v kontextu blended learningu využívá při analýzách data pouze ze dvou běhů dvou různých kurzů.

Přitom zvláště v kontextu blended learningu se zdají být otázky zobecnitelnosti velmi palčivé. Např. již zmiňovaní Jo, Park, Kim a Song (2014), kteří analyzovali data ze dvou typově odlišných blended kurzů, zjistili zásadní rozdíly v tom, které proměnné fungují jako prediktory úspěšnosti. Podobně také Estaciová a Raga (2017), kteří analyzovali čtyři různé kurzy, našli značnou variabilitu mezi jednotlivými kurzy, co se týče potenciálních prediktorů úspěšnosti studentů. Uzavírají tak, že právě povaha či design kurzů je zřejmě oním hlavním faktorem, který způsobuje variabilitu v účinnosti jednotlivých prediktorů. Joksimović et al. (2015) dochází na základě výsledků své studie k ještě o něco silnějšímu tvrzení a uvádí, že rozdíly mezi kurzy jsou dokonce v kontextu predikce úspěšnosti studentů důležitější, než rozdíly mezi jednotlivými studenty. Jako potenciálně důležité faktory na úrovni kurzů pak uvádí design kurzu, styl či způsob výuky učitele, využívané formy hodnocení a obor resp. disciplína, které se kurz týká. A přestože se studie nevěnuje přímo temporálním

charakteristikám návštěvnosti jakožto prediktorům úspěšnosti, její výsledky jsou extrémně důležité, jelikož jde o jednu z mála studií, která pracuje s relativně velkým počtem kurzů. Za velmi důležitou lze pak považovat i studii Gaševiče et al. (2016), která rovněž velmi silně zdůrazňuje, že vztah mezi aktivitou studentů v LMS a jejich následnými výsledky v kurzech je výrazně moderován různým designem kurzů. Autoři jsou přitom přesvědčeni, že tyto rozdíly v designu jednotlivých kurzů musí být brány v úvahu při snahách o tvorbu obecných prediktivních modelů. Nezhlednění těchto odlišností na úrovni kurzů podle nich povede k nadhodnocování či naopak podceňování vlivu jednotlivých indikátorů při predikci úspěšnosti studentů.

## 4.2. Výzkumný problém a otázky sondy A

S ohledem na výše uvedená východiska a prezentované dosavadní výzkumy usiluje tato studie o zodpovězení následující hlavní výzkumné otázky (HVO):

- *HVO: Jaké jsou možnosti predikce úspěšného absolvování blended kurzů na základě temporálních aspektů návštěvnosti jejich online opor v LMS?*

Výše uvedená hlavní výzkumná otázka se přitom v rámci této sondy rozpadá do tří specifických výzkumných otázek (SVO). První specifická výzkumná otázka se primárně věnuje možnostem predikce úspěšnosti studentů a jejím cílem je zjistit, jak se možnosti predikce mění při použití různých prediktivních technik, resp. které techniky a nakolik jsou v rámci predikce úspěšné. Jelikož je v analyzovaných datech úspěšnost studentů v kurzech vyjádřena v podobě binární proměnné (tj. úspěch versus neúspěch), jde v kontextu data miningu a strojového učení o typ úlohy označovaný jako klasifikace<sup>90</sup>. V tomto případě jde o binární klasifikaci, kdy je třeba na základě vstupních dat (tj. prediktorů – zde temporálních aspektů návštěvnosti) správně zařadit studenta do jedné ze dvou kategorií: úspěšné splnění kurzu či neúspěšné splnění kurzu.

Pro samotnou klasifikaci pak lze použít širokou škálu různých klasifikačních algoritmů, od relativně dlouho známé a i mimo oblast data miningu široce používané logistické regrese až po v dnešní době velmi populární umělé neuronové sítě. V kontextu analytiky učení a data miningu ve vzdělávání je predikce úspěšnosti studentů v kurzech za využití metody klasifikace jednou z nejvíce akcentovaných výzkumných oblastí (viz kapitola 2.3.2. či Papamitsiou & Economides, 2014; Peña-Ayala, 2014b). Mezi nejčastěji používané analytické techniky a klasifikační algoritmy pak spadá logistická regrese a algoritmy založené na technice

---

<sup>90</sup> V terminologii strojového učení bývá klasifikace rovněž považována za jednu z metod tzv. učení s učitelem.

rozhodovacích stromů (Peña-Ayala, 2014b). Při zjišťování možností predikce úspěšnosti studentů za využití různých analytických metod jsou tak jako klasifikační algoritmy využity primárně právě logistická regrese a rozhodovací stromy. Mimo to je rovněž použita technika náhodného lesa, která také vychází z rozhodovacích stromů a zároveň obvykle dosahuje lepších výsledků. Jako poslední klasifikační algoritmus je využita technika podpůrných vektorů, která zatím v kontextu analytiky učení a data miningu ve vzdělávání není příliš často využívána<sup>91</sup>. První specifickou výzkumnou lze tak formulovat následovně:

- *SVO1: Jaké jsou predikční schopnosti vybraných klasifikačních algoritmů (logistická regrese, rozhodovací strom, náhodný les a algoritmus podpůrných vektorů) při predikci úspěšnosti studentů v blended kurzech?*

V rámci druhé specifické výzkumné otázky je věnována pozornost analyzovaným temporálním aspektům návštěvnosti e-learningových opor blended kurzů v LMS. Cílem je přitom zjistit, které proměnné vyjadřující určité temporální aspekty návštěvnosti jsou pro predikci nejdůležitější (tj. nejpřínosnější z hlediska predikce úspěšnosti). Jak bylo naznačeno již v předchozí části, přestože existuje několik studií věnujících se temporálním aspektům návštěvnosti (např. Jo, Kim, & Yoon, 2015; Kim, Park, Yoon, & Jo, 2016; Kim, Yoon, Jo, & Branch, 2018; Miyamoto et al., 2015), zatím není dostatečně zřejmé, jaké konkrétní proměnné týkající se temporálních aspektů návštěvnosti jsou nejvhodnějšími prediktory úspěšnosti studentů. Zvláště doposud nebyla věnována dostatečná výzkumná pozornost temporálním aspektům návštěvnosti v kontextu blended kurzů, což se snaží tato sonda kompenzovat. Navíc autoři doposud realizovaných studií nepracovali s příliš velkými vzorky, které by obsahovaly větší množství různých kurzů. Druhou specifickou výzkumnou otázku této sondy lze proto formulovat následovně:

- *SVO2: Jaké proměnné týkající se temporálních aspektů návštěvnosti e-learningových opor blended kurzů v LMS Moodle jsou nejdůležitější při predikci úspěšnosti studentů?*

Třetí specifická výzkumná otázka se zaměřuje na ověření toho, nakolik jsou testované klasifikační algoritmy schopny predikovat úspěšnost studentů napříč různými blended kurzy, tzn., zda a případně nakolik je možné natrénovat klasifikační algoritmy na datech z určité množiny kurzů a následně predikovat úspěšnost studentů v jiné (zcela nové) množině kurzů. Jedno z důležitých specifík vzdělávacího kontextu je totiž to, že zkoumané fenomény na

---

<sup>91</sup> Přesto je nutné zmínit, že v několika studiích tato technika využita je (např. Rivera, Goel, & Kincaid; 2016; Şen, Uçar, & Denle, 2012; Zafra, Romero, & Ventura, 2011).

individuální úrovni bývají relativně často významně ovlivňovány vyššími úrovněmi jako je např. úroveň třídy (či úroveň kurzu v LMS) nebo úroveň školy. Tyto vyšší úrovně jsou přitom potenciálním zdrojem další variability (typicky např. rozdíly mezi různými školami), která je odlišná od variability na individuální úrovni. Ignorování víceúrovňové povahy zkoumaného fenoménu (resp. dat, která máme k dispozici) tudíž může vést k nesprávným závěrům. Specificky v souvislosti s predikcí úspěšnosti studentů v blended kurzech přitom dosavadní výzkumy naznačují, že na úrovni kurzů se skutečně nachází velké množství variability, která je dána především různou povahou a designem jednotlivých kurzů.

V kontextu českého pedagogického výzkumu se zatím zohledňování víceúrovňové povahy zkoumaného problému objevuje především v souvislosti s velkými mezinárodními výzkumy jako je PISA, ICLIS, TIMSS či PIRLS, které již z charakteru svého designu vyžadují víceúrovňovou analýzu dat (viz Juhaňák, Zounek, Záleská, Bárta, & Vlčková, 2018, 2019; Soukup, 2016; Straková, 2016). Přesto, jak upozorňuje např. Soukup (2006), důležitost zohledňování různých úrovní a využití odpovídajícího způsobu analýzy se týká i jiných zkoumaných oblastí nejen v rámci pedagogického výzkumu. V kontextu výzkumu v oblasti analytiky učení a data miningu ve vzdělávání se prozatím většina studií ve svých analýzách zaměřuje spíše na studenty jednoho či několika málo kurzů a nepracují tak s daty víceúrovňového charakteru (např. Estacio & Raga, 2017; Jo, Park, Kim, & Song, 2014; Lu, Huang, Lin, Ogata, & Yang, 2018; Sheshadri, Gitinabard, Lynch, Barnes, & Heckman, 2018; Yu & Jo, 2014). To ovšem znamená jednak to, že zobecnitelnost a aplikovatelnost takových zjištění může být značně omezená (v některých případech mohou výsledná zjištění platit skutečně pouze pro daný zkoumaný kurz), jednak není doposud dostatečně známo, nakolik se víceúrovňová povaha dat (tj. data týkající se studentů v různých kurzech) promítá do predikčních schopností klasifikačních algoritmů běžně používaných v oblasti LA a EDM. Třetí specifickou otázkou pokládanou v této sondě lze tudíž formulovat následovně:

- *SVO3: Jak se mění míra úspěšné predikce vybraných klasifikačních algoritmů (logistická regrese, rozhodovací stromy, náhodný les a podpůrné vektory) při jejím testování externí validací a při zohlednění dvouúrovňového charakteru dat?*

### **4.3. Metodologie sondy A**

Charakter této studie lze vzhledem ke stanoveným cílům považovat především za evaluační. A to v tom smyslu, že usiluje primárně o zhodnocení účinnosti jednotlivých prediktivních metod a použitých prediktorů týkajících se temporálních aspektů návštěvnosti blended kurzů v LMS Moodle. V následujících částech této metodologické kapitoly bude nejprve představena problematika klasifikace jakožto obecný metodologický přístup použitý

k predikci úspěšnosti studentů v této sondě. Poté budou podrobně popsána analyzovaná data a představeny použité proměnné. V závěru kapitoly je pak podrobně nastíněn proces analýzy a evaluace jednotlivých klasifikačních algoritmů.

#### 4.3.1. Metodologický přístup – klasifikace

V kontextu data miningu a strojového učení jsou dílčí metodologické oblasti či směry, kterým výzkumníci věnují pozornost, obvykle rozdělovány podle základního problému či úkolu, na jehož řešení se primárně zaměřují. Jedním z takových problémů a zároveň jednou z hlavních oblastí data miningu a strojového učení tvoří právě problém klasifikace. V případě klasifikace přitom jde o takový druh problému či úkolu, v rámci kterého je cílem správné zařazení nového (doposud neznámého) případu do odpovídající z možných kategorií, a to na základě dostupných (trénovacích) dat obsahujících jiné případy, u kterých je správné zařazení známo (Gorunescu, 2011).

Samotný proces klasifikace je možné popsat na základě jeho následujících součástí (srov. Dean, 2014; Gorunescu, 2011; Han & Kamber, 2006; Witten, Frank, & Hall, 2011):

- **Třída** (*class*) není nic jiného než závisle proměnná kategorického charakteru, se kterou při klasifikaci pracujeme a kterou se snažíme predikovat. V případě této sondy je tedy třídou závisle proměnná indukující, zda student úspěšně ukončil kurz či nikoli (tj. jde o binární klasifikaci, jelikož je třída tvořena pouze dvěma kategoriemi).
- **Prediktory**. Vedle třídy musíme mít sadu dalších proměnných, na základě kterých pak bude docházet k odhadu správné kategorie v rámci třídy. Tyto další proměnné se označují jako prediktory (někdy též vlastnosti či atributy aj.) a odpovídají tomu, co v „tradičním“ statistickém výzkumu bývá označováno jako nezávisle proměnné.
- **Trénovací data**. Při klasifikaci rozlišujeme dva druhy dat: trénovací a testovací data. Trénovací data jsou taková data, která obsahují obě výše uvedené složky (tj. třídu a sadu prediktorů) a která jsou použita pro trénování klasifikačního modelu pomocí určitého klasifikačního algoritmu.
- **Klasifikační algoritmus** lze chápat jako specifický postup, pomocí kterého dochází k tvorbě klasifikačního modelu na základě vstupních (trénovacích) dat. Cílem klasifikačního algoritmu je tedy na základě dostupných dat nalézt co možná nejlepší (obvykle nej přesnější) klasifikační model. Způsob hledání a tvorby klasifikačního modelu se pak liší v závislosti na konkrétním klasifikačním algoritmu. V této sondě jsou přitom využity následující klasifikační algoritmy:

logistická regrese, rozhodovací strom, náhodný les a algoritmus podpůrných vektorů.

- **Klasifikační model** je výstupem klasifikačního algoritmu aplikovaného na trénovacích datech. Jde o model (z matematického hlediska funkci), který na základě sady prediktorů přiřazuje každý případ do odpovídající kategorie v rámci třídy. Klasifikační model je tedy tou komponentou, která následně zajišťuje predikci pro nové případy, u kterých již neznáme správnou kategorii v rámci dané třídy.
- **Testovací data** jsou data, která se používají k evaluaci vytvořeného klasifikačního modelu. Strukturně jsou stejná jako trénovací data (tj. opět obsahují prediktory a třídu), všem nejsou využita při trénování klasifikačního modelu<sup>92</sup>. Data v testovacím souboru se na základě dostupných prediktorů nechají klasifikovat pomocí vytvořeného klasifikačního modelu. Srovnáním skutečných hodnot v rámci třídy s těmi predikovanými pak dochází ke zhodnocení výkonu modelu.

Konkrétnější informace o způsobu využití klasifikace v rámci sondy A jsou prezentovány v části 4.3.4. *Postup analýzy dat*.

#### **4.3.2. Analyzovaná data, sběr a předzpracování dat**

Data použitá v následujících analýzách tvoří celkem 2321 studentů studujících v 35 různých blended kurzech s různou mírou využití online podpory v LMS. Všechny kurzy probíhaly v LMS Moodle na Filozofické fakultě Masarykovy univerzity a byly vyučovány v průběhu jednoho semestru. Konkrétně šlo o jarní semestr 2014. Kritérium pro výběr kurzů bylo dvojí:

1. Hlavním kritériem bylo to, zda byla v rámci kurzů dostupná informace o minimálních požadavcích na studenty pro splnění kurzu<sup>93</sup>. Zároveň musela být v rámci kurzu využita nějaká forma sledování plnění stanovených požadavků<sup>94</sup>, jež

---

<sup>92</sup> Běžný postup při klasifikaci je tudíž takový, že se dostupná data nejprve rozdělí na trénovací a testovací, přičemž testovací data nejsou využívána, dokud nedojde k vytvoření klasifikačního modelu a nepřístupí se k jeho hodnocení.

<sup>93</sup> Tj. v kurzu byla vždy stanovena jednoznačná hranice, co musí student splnit, aby úspěšně absolvoval kurz. V zásadě šlo o stanovení bodové hranice, kterou musí student získat, aby úspěšně absolvoval kurz.

<sup>94</sup> Tj. pro každého studenta bylo sledováno (s)plnění stanovených aktivit v online podpoře kurzu. V zásadě šlo o využití funkce pro zadávání známek resp. bodového hodnocení k jednotlivým aktivitám studentů. Tzn., vyučující v daném kurzu tuto funkcionalitu musel využívat a aktivity studentů hodnotit. Pro kontext je možné doplnit, že v LMS Moodle na FF MU není neobvyklá situace, kdy vyučující ve svých kurzech tuto funkci vůbec nevyužívají.

umožňovala rozlišit studenty, kteří splnili stanovené požadavky (a tím úspěšně absolvovali kurz) a kteří nikoli.

2. Doplnujícím kritériem pak byla velikost kurzů ve smyslu počtu studentů, kteří daný kurz studují. Vybrány byly jen takové kurzy, ve kterých studovalo více jak 25 studentů. Hlavním důvodem pro zaměření pozornosti spíše na větší kurzy bylo to, aby v rámci jednotlivých kurzů bylo dostatek jednotek pro trénování použitých klasifikačních algoritmů. Celkově se počet studentů ve vybraných kurzech pohyboval od 26 do 334, přičemž střední hodnota ( $Me$ ) byla 47 studentů v kurzu.

Po extrakci dat z databáze systému Moodle bylo hlavním úkolem jejich transformování do takové podoby, v níž by mohly vstupovat do plánovaných analýz. Výchozí data o návštěvnosti kurzů jsou totiž v systému LMS ukládána pomocí tzv. logů (viz tabulka 6). Každý záznam o aktivitě studenta (tj. log) v LMS pak obsahuje mimo jiné unikátní identifikátor ( $log.id$ ), informaci o čase, kdy k aktivitě došlo ( $log.time$ ), identifikátor uživatele, který aktivitu provedl ( $log.userid$ ), identifikátor kurzu, ve kterém byla aktivita provedena ( $log.courseid$ ), informaci o tom, v jakém nástroji či v jakém kontextu aktivita proběhla ( $log.module$ ), identifikátor konkrétního nástroje či kontextu ( $log.cmid$ ) a informaci o tom, jaký typ aktivity byl proveden ( $log.action$ ).

Tabulka 6: Příklad tabulky logů v LMS Moodle<sup>95</sup> (identifikátory byly anonymizovány).

<b>log.id</b>	<b>log.time</b>	<b>log.userid</b>	<b>log.courseid</b>	<b>log.module</b>	<b>log.cmid</b>	<b>log.action</b>
100	12.06.2014 23:58	111	123	course	123456	view
200	13.06.2014 1:03	222	123	course	123456	view
300	13.06.2014 1:26	222	123	course	123456	view
400	19.06.2014 14:13	333	123	resource	232323	view
500	19.06.2014 14:15	333	123	resource	232323	view
600	19.06.2014 14:20	333	123	resource	232323	view
700	02.03.2014 11:38	444	321	url	445544	view
800	02.03.2014 11:38	444	321	url	445544	view
900	16.06.2014 14:36	555	321	quiz	363636	attempt
1000	16.06.2014 14:39	555	321	quiz	363636	attempt
1100	16.06.2014 14:39	555	321	quiz	363636	attempt

<sup>95</sup> Nutno doplnit, že v současnosti již systém Moodle pracuje s bohatší tabulkou logů, která obsahuje více údajů.

Cílem transformace dat bylo převedení výchozích dat v podobě logů do podoby souhrnných dat, která by na každém řádku obsahovala určitého studenta určitého kurzu, a v rámci jednotlivých sloupců by poskytovala agregované informace o návštěvnosti daného studenta v daném kurzu (za využití jednotlivých ukazatelů návštěvnosti použitých v této sondě), a nadto informaci o úspěšnosti či neúspěšnosti daného studenta při absolvování daného kurzu. Teprve po této transformaci dat bylo možné přistoupit k samotné analýze a aplikaci klasifikačních algoritmů.

### 4.3.3. Použité proměnné

Jako závisle proměnná resp. třída figuroval v datech binární indikátor (Ano/Ne, resp. 1/0) toho, zda student splnil minimální požadavky pro ukončení kurzu a tedy zda úspěšně splnil kurz. V podobě nezávisle proměnných resp. prediktorů pak do realizovaného modelování vstupovalo několik kvantitativních temporálních charakteristik návštěvnosti blended kurzů resp. online studijních opor blended kurzů. Výběr nezávisle proměnných, které byly v této sondě využity, vycházel ze studia dosavadní literatury věnující se problematice temporálních aspektů návštěvnosti blended kurzů (viz kapitola 4.1.2.). Celkem bylo v realizovaných analýzách využito devět různých prediktorů. Pro účely jejich popisu lze přitom ovšem hovořit o pěti základních skupinách proměnných.

V první skupině tvořené třemi proměnnými se vychází z počtu záznamů o aktivitě studenta v kurzu (tj. z celkového počtu logů). Pro zjednodušení lze tuto míru chápat jako počet kliknutí myši v rámci kurzu<sup>96</sup>. Celkový počet záznamů o aktivitě byl přitom spočítán zvlášť za tři různá období v průběhu semestru: období výuky, zkouškové období a prodloužené zkouškové období (jak bylo řečeno, šlo o jarní semestr). Přesné vymezení jednotlivých tří období se řídilo oficiálním harmonogramem Filozofické fakulty Masarykovy univerzity pro daný semestr. První skupinu proměnných tedy tvoří následující (v závorce je uveden zkrácený název používaný dále v textu a především v tabulkách):

- Celkový počet záznamů o aktivitě studenta v průběhu výuky (*Počet záznamů – výuka*).
- Celkový počet záznamů o aktivitě studenta v průběhu zkouškového období (*Počet záznamů – zkouškové*).

---

<sup>96</sup> Tato paralela slouží pouze jako přiblížení. Ve skutečnosti se totiž nezaznamenává úplně každé kliknutí myši. Zároveň mohou naopak některé aktivity studenta v kurzu vygenerovat více jak jeden záznam v logovacím systému na jedno kliknutí myši.



- Celkový počet záznamů o aktivitě studenta v průběhu prodlouženého zkouškového období (*Počet záznamů – p. zkouškové*).

Druhou skupinu proměnných tvoří počty návštěv studentů v kurzech. Konceptuálně se návštěvou v tomto kontextu chápe situace, kde student vstoupí do kurzu v LMS, nějakou dobu se zde pohybuje či pracuje a následně kurz a práci v něm opouští. Když se student po nějaké době (např. za týden) do kurzu opět vrací, jde již o další návštěvu. Technicky však nelze jednotlivé návštěvy zcela přesně odlišit, jelikož konec návštěvy obvykle není v systému nijak explicitně zaznamenáván (tj. student jednoduše přestane v systému pracovat a zavře okno prohlížeče, aniž by se ze systému explicitně odhlásil kliknutím na odpovídající tlačítko). Proto bývá rozlišení jednotlivých návštěv obvykle (viz např. Kovanović et al., 2015) řešeno tak, že je stanovena určitá prahová hodnota neaktivity, která indikuje konec návštěvy. V případě této sondy byla zvolena prahová hodnota neaktivity 30 minut. Zjednodušeně to lze chápat tak, že pokud student v kurzu průběžně kliká myší a následně alespoň třicet minut systém nezaznamená v kurzu od daného studenta žádné kliknutí, je to vyhodnoceno tak, že studentova návštěva v kurzu skončila.<sup>97</sup> I v případě počtu návštěv přitom byla věnována pozornost výše uvedeným třem obdobím v průběhu semestru, celkem jsem tedy pracoval s následujícími třemi proměnnými:


- Celkový počet návštěv studenta v kurzu v průběhu výuky (*Počet návštěv – výuka*).
- Celkový počet návštěv studenta v kurzu v průběhu zkouškového období (*Počet návštěv – zkouškové*).
- Celkový počet návštěv studenta v kurzu v průběhu prodlouženého zkouškového období (*Počet návštěv – p. zkouškové*).

V souvislosti s návštěvností byly pro každého studenta a každý kurz vypočítány další dvě proměnné, které byly následně použity ve všech analýzách. První proměnná odpovídá době od začátku kurzu do prvního přihlášení studenta do e-learningové podpory kurzu (*První návštěva kurzu*), druhá pak vyjadřuje pravidelnost (resp. nepravidelnost), s jakou student do kurzu přistupuje (*Pravidelnost návštěv*). V případě proměnné *První návštěva kurzu* je použitou jednotkou počet dní od začátku kurzu do prvního přihlášení studentem do kurzu.

---

<sup>97</sup> Že využití tohoto postupu nemusí být vždy zcela přesné lze v kontextu využití LMS ilustrovat např. situací, kdy má student otevřen (rozsáhlý) studijní materiál, který čte déle než je stanovená prahová hodnota (např. 30 minut). V tomto okamžiku student v kurzu reálně pracuje, ovšem jeho aktivita (tj. čtení studijního materiálu) se neodráží v klikání myší, a tudíž je to vyhodnoceno jako konec návštěvy v kurzu. Podobnou situaci může být např. sledování delšího naučného videa v kurzu.

V případě pravidelnosti návštěv pak jde o směrodatnou odchylku časových intervalů mezi jednotlivými návštěvami kurzu (srov. Jo, Kim, & Yoon, 2015; Kim, Park, Yoon, & Jo, 2016; Kim, Yoon, Jo, & Branch, 2018). Pro lepší pochopení výpočtu této proměnné lze využít obrázek níže (viz obrázek 14) znázorňující celkové trvání kurzu pomocí úsečky, jejímiž krajními body jsou začátek a konec kurzu. V průběhu trvání kurzu pak jednotliví studenti kurz v určitých časových okamžicích navštěvují, což znázorňují body  $t_1$  až  $t_n$  (zcela přesně řečeno jde o časy začátku jednotlivých návštěv). Vzdálenost mezi body  $t_1$  a  $t_2$  (tj.  $\Delta t_{1,2}$ ) pak odpovídá časovému intervalu mezi první a druhou návštěvou studenta, který je vypočítán tak, že se od času  $t_2$  odečte čas v bodu  $t_1$ . Obdobně je tomu pak v případě intervalu  $\Delta t_{2,3}$  a ve všech dalších časových intervalech až po poslední interval  $\Delta t_{n-1,n}$ . Z těchto hodnot je pak vypočítána směrodatná odchylka, která vypovídá o tom, nakolik se od sebe liší délka časových intervalů mezi návštěvami. Čím je hodnota směrodatné odchylky menší, tím pravidelněji student kurz navštěvuje.



Obrázek 14: Konceptualizace časových intervalů mezi jednotlivými návštěvami kurzu (dle Jo, Kim, & Yoon, 2015).

Poslední použitou proměnnou je pak celkový čas strávený studentem v e-learningové podpoře kurzu v průběhu celého semestru (*Celkový čas v kurzu*), přičemž jednotkou je zde počet minut. V rámci této proměnné se opět vychází z prahové hodnoty 30 minut neaktivity, která signalizuje konec návštěvy studenta v kurzu. Jako délka trvání návštěvy je přitom počítán čas od prvního záznamu aktivity po předchozí 30 minutové neaktivitě (příp. od úplně prvního záznamu aktivity studenta v kurzu) až po nejbližší nadcházející záznam aktivity, který předchází další 30 minutové neaktivitě<sup>98</sup>. K této hodnotě je přitom za každou návštěvu připočítána tzv. kompenzace času stráveného na poslední aktivitě. Jak bylo již zmíněno, studenti obvykle nekončí svoji práci tím, že by klikli na tlačítko pro odhlášení se systému,

<sup>98</sup> Pro snadnější pochopení je relativně přesným přiblížením to, že se v tomto kroku jednoduše spočítá doba mezi prvním a posledním kliknutím studenta v kurzu v rámci jedné návštěvy.

nýbrž jednoduše zavřou okno ve svém prohlížeči. To vede k tomu, že není zaznamenán čas strávený v kurzu na poslední aktivitě před skutečným odchodem z kurzu<sup>99</sup>. Přestože není samozřejmě možné zjistit skutečnou délku trvání této poslední aktivity, je alespoň jako určitá aproximace použita právě kompenzace času na poslední aktivitě. Ta je konkrétně vypočítána jako průměr časových intervalů mezi jednotlivými záznamy o aktivitě studenta v průběhu návštěv v kurzu<sup>100</sup>.

Z celkového počtu 2321 studentů jich 1462 (63 %) splnilo minimální požadavky pro úspěšné ukončení kurzu. Zbývajících 859 (37 %) neukončilo studovaný kurz úspěšně. Základní deskriptivní údaje o nezávisle proměnných (prediktorech) jsou pak k dispozici v následující tabulce.

*Tabulka 7: Deskriptivní popis nezávisle proměnných (tj. prediktorů).*

	<b>Min</b>	<b>Max</b>	<b>Průměr</b>	<b>Medián</b>	<b>SD</b>
Počet záznamů – výuka	0	2106	185,2	42	339,3
Počet záznamů – zkouškové	0	1604	51,9	1	125,5
Počet záznamů – p. zkouškové	0	370	1,1	0	11,1
Počet návštěv – výuka	0	274	14,5	8	23,6
Počet návštěv – zkouškové	0	131	3,3	1	7,3
Počet návštěv – p. zkouškové	0	59	0,2	0	2,01
První přihlášení	0,005	196,6	21,3	9,4	27,3
Pravidelnost návštěv	0,026	63,9	10	6,7	9,7
Celkový čas v kurzu	0	4111,1	233,4	85	363,1

#### **4.3.4. Postup analýzy dat**

Za účelem zodpovězení stanovených výzkumných otázek bylo provedeno srovnání predikčních schopností čtyř různých klasifikačních algoritmů (logistická regrese, rozhodovací

<sup>99</sup> Příkladem je následující situace: student nějakou dobu pracuje v kurzu a na závěr své návštěvy si ještě kliknutím otevře studijní materiál, který následně nějakou dobu čte. Poté zavře okno prohlížeče a vypne počítač. Poslední záznam o aktivitě v rámci návštěvy je tak okamžik, kdy si otevřel studijní materiál. Ve skutečnosti však ještě trávil nějaký čas čtením otevřeného studijního materiálu, a proto je žádoucí tento čas (resp. jeho odhad) k naměřenému trvání návštěvy připočíst.

<sup>100</sup> Můžeme si to představit tak, že v rámci svých návštěv v kurzu dělá student různé aktivity (plnění testu, komunikace ve fóru apod.), které mu zaberou různé množství času. Kompenzace času na poslední aktivitě je pak průměrná doba trvání těchto aktivit.

stromy, náhodný les a podpůrné vektory), přičemž byly využity tři různé způsoby predikčního testování. V prvním kroku byla použita kompletní data a výchozí metoda testování modelu v rámci daného klasifikačního algoritmu<sup>101</sup>. V druhém kroku byly všechny testované algoritmy podrobeny testování tzv. externí validací, v rámci které jsou data rozdělena na trénovací a testovací část. Jak naznačuje pojmenování obou částí, trénovací část je pak využita k natrénování klasifikačního algoritmu, zatímco testovací část slouží k otestování úspěšnosti predikce na zcela nových datech. Rozdělení souboru na trénovací a testovací část bylo provedeno v poměru dvě ku jedné, tzn., že dvě třetiny dat byly použity pro trénování klasifikátoru a jedna třetina pro jeho testování. Zároveň, aby nedošlo ke zkreslení způsobenému konkrétním výběrem trénovacích a testovacích dat, byla využita varianta externí validace s  $r$  opakováními (Holčík & Komenda, 2015). Při této variantě nedochází k rozdělení na trénovací a testovací část dat pouze jednou, nýbrž se soubor náhodně rozdělí  $r$ -krát a získaných  $r$  výsledků je poté zprůměrováno. Hlavní výhodou tohoto přístupu je přesnější odhad úspěšnosti klasifikace. V rámci této sondy bylo při externí validaci využito 100 opakování.

Ve třetím kroku byla opět aplikována externí validace se 100 opakováními při poměru dvě třetiny na trénink a třetina na testování, ovšem navíc byla při rozdělování dat na trénovací a testovací množinu zohledňována úroveň jednotlivých kurzů. Tzn., že bylo zajištěno, aby všichni studenti ze stejného kurzu byli buď v trénovací, nebo testovací množině. V trénovací množině tedy byla data týkající se jiných kurzů než v testovací množině. Taková forma externí validace byla zvolena proto, aby bylo možné ověřit, nakolik jsou klasifikační algoritmy schopny úspěšné predikce v případě, kdy jsou natrénované na určité množině kurzů a následně testované na zcela nových kurzech.

Při aplikaci klasifikačních algoritmů a vlastním modelování byl přítom ve všech fázích predikčního testování následován běžný postup popisovaný řadou odborných publikací věnujících se data miningu či strojovému učení (viz např. Gorunescu, 2011; Kelleher, Mac Namee, & D'Arcy, 2015; Witten, Frank, & Hall, 2011). Konkrétně lze tento postup popsat následovně:

- 1. Tvorba a vyhodnocení výchozího modelu.** Nejprve proběhlo předzpracování dat z vybraných kurzů, jak bylo popsáno v kapitole 4.3.2., a byla vytvořena finální datová sada obsahující devět nezávisle proměnných, jednu závisle proměnnou

---

<sup>101</sup> Bude popsáno v sekci výsledků přímo u jednotlivých klasifikačních algoritmů.

a jednu proměnnou sloužící jako identifikátor kurzu<sup>102</sup>. Všech devět nezávisle proměnných pak bylo využito při tvorbě výchozího modelu predikujícího binární třídu. V rámci vyhodnocování úspěšnosti výchozího modelu byla vždy vytvořena 2×2 kontingenční tabulka predikovaných a skutečných hodnot a zároveň zobrazena tzv. ROC (*Receiver Operating Characteristic*) křivka běžně využívaná při evaluaci a optimalizaci binárního klasifikátoru. S využitím vytvořené kontingenční tabulky a ROC křivky pak byly vypočítány čtyři základní indikátory, na základě kterých byla posuzována kvalita modelu. Konkrétně šlo o přesnost, senzitivitu, specificitu a plochu pod ROC křivkou (běžně označováno anglickou zkratkou *AUC – Area Under the Curve*)<sup>103</sup>.

**2. Hledání a výběr parametrů modelu (tzv. *parameter tuning*).** Po tvorbě výchozího modelu probíhalo hledání a výběr optimálních parametrů klasifikačního algoritmu. Tato fáze se samozřejmě lišila podle jednotlivých klasifikačních algoritmů a toho, jaké parametry tyto algoritmy vyžadují specifikovat. Ve všech případech byly parametry vybírány tak, aby byla co možná nejvíce zvýšena schopnost modelu správně predikovat úspěšnost studentů v blended kurzech. V případě logistické regrese docházelo k hledání optimálního cut-off skóre pomocí tzv. Youdenova indexu (Youden, 1950). U rozhodovacích stromů probíhalo hledání optimální hodnoty parametru složitosti (*complexity parameter*), který určuje složitost resp. velikost rozhodovacího stromu a umožňuje vybrat optimálně veliký/složité rozhodovací strom (Therneau & Atkinson, 2018). V případě náhodného lesa byla vybírána optimální hodnota parametru *mtry*, která specifikuje počet proměnných náhodně vybraných pro účely dělení stromu na každém uzlu (Liaw & Wiener, Classification and Regression by randomForest, 2002). Přestože v odborných zdrojích panuje diskuze ohledně vlivu tohoto parametru na úspěšnost klasifikace, většina zdrojů jej zmiňuje a doporučuje mu

---

<sup>102</sup> Identifikátor kurzu byl využit pouze při rozdělování dat na trénovací a testovací množinu. Při samotném modelování tato proměnná využita nebyla.

<sup>103</sup> Doplňme, že přesnost odpovídá poměru mezi množstvím skutečně pozitivních a skutečně negativních případů k celkovému množství případů (tj. kolik procent případů bylo klasifikováno správně). Senzitivita odpovídá poměru mezi počtem pravdivě pozitivních případů a součtu pravdivě pozitivních případů s falešně negativními případy (tj. kolik procent ze skutečně pozitivních případů bylo klasifikováno správně, resp. nakolik dochází ke správně klasifikaci úspěšných studentů). Specifická pak odpovídá poměru mezi počtem pravdivě negativních případů a součtu falešně pozitivních případů s pravdivě negativními případy (tj. kolik procent ze skutečně negativních případů bylo klasifikováno správně, resp. nakolik dochází ke správně klasifikaci neúspěšných studentů).

věnovat pozornost. V případě náhodného lesa byl vždy zároveň specifikován počet stromů (tj. parametr *n<sub>tree</sub>*), a to tak, aby byla volená hodnota dostatečně vysoká. Při použití algoritmu podpůrných vektorů byla pro hledání vhodných hodnot parametrů využita technika vyhledávání v mřížce (*grid search*), přičemž byly hledány optimální hodnoty parametrů *epsilon* a *cost* (Kuhn M. , 2018).

- 3. Tvorba a vyhodnocení výsledného modelu.** Na základě předchozího kroku byl vytvořen výsledný model, ve kterém již byly specifikovány nalezené vhodné parametry modelu. Výsledný model byl opět vyhodnocen stejným způsobem jako výchozí model, tj. pomocí kontingenční tabulky, ROC křivky, přesnosti, senzitivity, specificity a hodnoty AUC.

Vzhledem k relativní komplikovanosti analytického postupu jsou některé dílčí analytické postupy či pojmy přesně popsány či vysvětleny až v sekci výsledků přímo v souvislosti s konkrétním krokem analýzy vedoucím k prezentovaným výsledkům.

## 4.4. Výsledky sondy A

Základní popisné charakteristiky analyzovaných dat uvádí tabulka výše (viz tabulka 7). Jak je z tabulky patrné, proměnné nemají normální rozdělení (spíše mají blízko k exponenciálnímu rozdělení). Ovšem, vzhledem k tomu, že logistická regrese ani ostatní klasifikační algoritmy nemají jako svůj předpoklad normální rozdělení, vstupovaly všechny proměnné do modelů v původní podobě bez jakýchkoli dalších transformací.

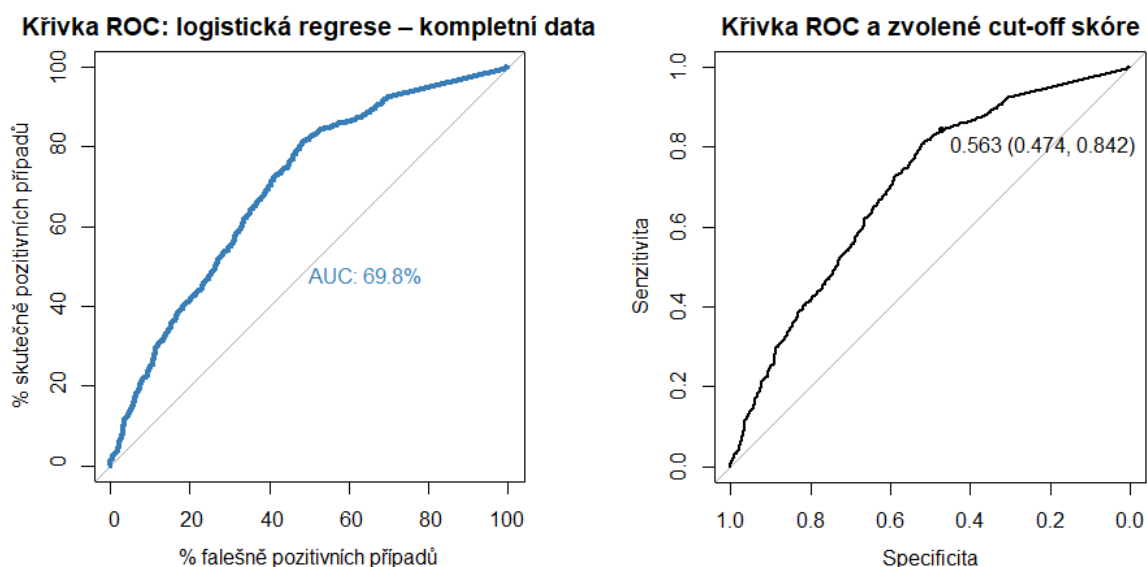
V následujících částech proběhne nejprve základní posouzení predikčních schopností analyzovaných klasifikačních algoritmů za použití kompletní datové sady a výchozí metody validace. Poté jsou prezentovány výsledky hodnocení důležitosti použitých prediktorů týkající se temporálních aspektů návštěvnosti blended kurzů. Zároveň je provádím srovnání důležitosti jednotlivých prediktorů při použití různých klasifikačních algoritmů. Na závěr prezentuji výsledky predikčního testování použitých algoritmů pomocí externí validace, a to jak bez zohlednění úrovně kurzů, tak i při jejím zohlednění.

### 4.4.1. Základní posouzení predikčních schopností analyzovaných klasifikátorů

Než jsem přistoupil k samotné aplikaci klasifikačních algoritmů, byla nejprve vypočtena základní úroveň přesnosti či tzv. *baseline model*, se kterým jsou všechny následné modely srovnávány. Pro výpočet základní úrovně přesnosti byla využita technika volby nejčastější kategorie. Baseline model si lze tedy představit jako takový, který za všech okolností predikuje

tu kategorii, která je v datech zastoupena nejčastěji. V našem případě tvoří závisle proměnnou pouze dvě kategorie: úspěch v kurzu a neúspěch v kurzu. Přitom z celkového počtu 2321 studentů, byla větší část (tj. 1462 studentů) úspěšná. Baseline model bude tedy u všech studentů predikovat úspěšnost, což povede ke správné predikci v 62,99 % případů. Za základní úroveň přesnosti je tak možné považovat 63 %.

Při použití **logistické regrese** jakožto klasifikačního algoritmu a kompletních dat pro účely trénování bylo dosaženo přesnosti 70,6 %, čili v o něco málo více jak 70 % případů byla správně predikována úspěšnost studenta na základě použitých proměnných týkajících se časových charakteristik návštěvnosti kurzů. Došlo tedy k zlepšení predikce o 7,6 %. Jako cut-off skóre byla zvolena hodnota 0,563, která byla určena pomocí vážené varianty Youdenova indexu (Youden, 1950). Youdenův index funguje v základní variantě tak, že jako optimální cut-off skóre volí takovou hodnotu na křivce ROC, která maximalizuje vzdálenost od diagonální čáry (viz obrázek 15). Vážená varianta Youdenova indexu zohledňovala poměr obou kategorií v závisle proměnné a byla zvolena proto, že přinášela mírně větší přesnost predikce než nevážená varianta.



Obrázek 15: Křivka ROC při použití logistické regrese jako klasifikačního algoritmu a kompletních dat pro účely tréninku (vlevo) včetně vyznačeného cut-off skóre (vpravo).

Na základě zvoleného cut-off skóre byla v tomto případě výsledná hodnota senzitivity 84,2 % a u specifity 47,4 %. Z toho lze usoudit, že tento logistický model je relativně úspěšný v predikci úspěšných studentů (cca 4 z 5 úspěšných studentů predikuje správně), ale relativně slabý v predikci neúspěšných studentů (každého druhého neúspěšného studenta predikuje

nesprávně). Při volbě jiného cut-off skóre by bylo možné vylepšit správnost predikce neúspěšných studentů, ovšem pouze při snížení celkové úspěšnosti predikce (tj. snížila by se schopnost predikovat úspěšné studenty)<sup>104</sup>.

Při použití algoritmu typu **rozhodovací strom** byla opět použita kompletní data pro účely trénování, ovšem zároveň bylo využito tzv. prořezávání (*pruning*) a 10-násobná křížová validace pro výběr finálního stromu. Konkrétně byl nejprve vytvořen tzv. úplný strom (*complete tree*), při jehož tvorbě nebyl parametr složitosti nijak omezen (tj. byl roven nule). Tento strom byl samozřejmě příliš velký (celkem 86 větví), takže jsem přistoupil k jeho prořezávání, tzn. omezování počtu větví, a tím pádem zjednodušování stromu. V rámci prořezávání stromu je za použití 10-násobné křížové validace vypočítávána míra tzv. klasifikační chyby (*cross-validated classification error*), a následně je vybrán strom s co nejméně větvemi a zároveň co nejnižší klasifikační chybou<sup>105</sup>. Při použití kompletních dat vedl tento postup k výběru rozhodovacího stromu s celkem 11 větvemi, který je zobrazen na obrázku níže (viz obrázek 16).

Výhodou rozhodovacích stromů je jejich velmi jednoduchá interpretovatelnost. Na základě rozhodovacího stromu na obrázku 16 tak můžeme velmi jednoduše vidět, podle jakých kritérií probíhá rozhodování o tom, jestli bude určitý student na základě predikce označen za úspěšného či neúspěšného. Zároveň je prezentována informace o poměru správně klasifikovaných případů k celkovému počtu případů v dané větvi a o celkovém procentu případů tvořících danou větev v rámci celého stromu. Z obrázku tak vidíme, že první rozhodovací kritérium v rámci stromu se týká celkového času stráveného v kurzu, přičemž je stanoveno kritérium „menší než 4,9 minut“. Pokud se jako příklad vezmou studenti, kteří v e-learningové podpoře kurzu strávili méně než 4,9 minut, pak je druhým rozhodovacím kritériem to, zda má student v průběhu zkuškového období méně než 8 záznamů o aktivitě v kurzu. Pokud nikoli (tj. má ve zkuškovém období více jak 8 záznamů), pak je predikován jako úspěšný. Úspěšnost klasifikace je přitom v této větvi 42/54 (tj. 77,8 %). Do této větve však spadají pouze 2 % celkového počtu studentů v analyzovaných datech. Zároveň se nabízí poměrně přímočará interpretace toho, o jaké studenty (s ohledem na jejich studium v blended

---

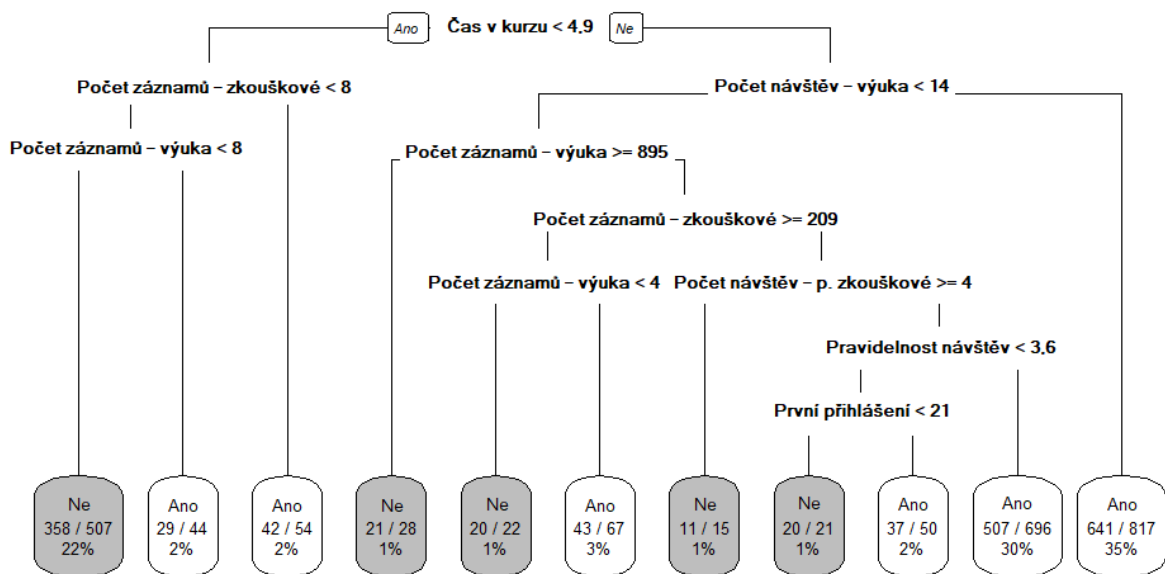
<sup>104</sup> Doplníme, že z praktického či aplikačního hlediska může být skutečně vhodné zvýšit specifitu i za cenu celkově horší přesnosti. Pokud by totiž účelem použití tohoto modelu byla identifikace rizikových studentů, kterým hrozí neúspěch v kurzu (viz kapitola 2.3.2.), pak by pro nás bylo důležitější správně identifikovat co nejvíce těchto studentů a pomoci jim kurz dokončit, a to i za cenu toho, že by častěji došlo k označení nerizikového studenta za rizikového.

<sup>105</sup> Pro podrobný a přesný popis, jak je vypočítávána klasifikační chyba na základě 10-násobné křížové validace (viz Therneau & Atkinson, 2018).



kurzu) se jedná. Jsou to studenti, kteří v online podpoře strávili v průběhu semestru minimální množství času, ale zároveň ve zkuškovém období projevili alespoň nějakou aktivitu v kurzu (např. odevzdání závěrečného úkolu). Obdobným způsobem pak lze analyzovat i ostatní větve rozhodovacího stromu.


Vizualizace rozhodovacího stromu – kompletní data



Obrázek 16: Vytvořený rozhodovací strom při použití kompletních dat.

Co se týče predikčních schopností výše znázorněného rozhodovacího stromu při použití kompletních dat pro účely trénování, pohybuje se přesnost predikce na úrovni 74,5 %, což je zlepšení predikce o 11,5 % oproti výchozímu modelu a o 3,9 % oproti logistickému modelu. Senzitivita rozhodovacího stromu je pak na úrovni 88,9 % a Specificita na úrovni 50,1 %. V obou případech je zde patrné zlepšení oproti logistickému modelu, ale stejně jako logistický model není ani rozhodovací strom schopen příliš přesně predikovat neúspěšné studenty (zato ty úspěšné ale predikuje téměř s devadesátiprocentní úspěšností). obrázek 17 pro srovnání zobrazuje křivku ROC daného rozhodovacího stromu a zároveň hodnotu plochy pod křivkou (AUC).


**Křivka ROC: rozhodovací strom – kompletní data**



Obrázek 17: Křivka ROC při použití rozhodovacího stromu jako klasifikačního algoritmu a kompletních dat pro účely trénování algoritmu.

Algoritmus **náhodný les** funguje tak, že vytváří větší množství rozhodovacích stromů, přičemž jednotlivé vytvořené stromy nejsou trénovány na celém datovém souboru, nýbrž jen na určité množině náhodně vybraných případů. Přestože tedy v případě náhodného lesa byla pro účely trénování použita kompletní data, ve skutečnosti technika opakovaného náhodného výběru pro tvorbu každého jednotlivého stromu dělá v podstatě to, že je kompletní datová sada rozdělena na řadu menších trénovacích a testovacích množin. Při predikci úspěchu či neúspěchu studentů v blended kurzech pomocí náhodného lesa bylo určeno, aby bylo vytvořeno celkem 500 dílčích rozhodovacích stromů. Důvodem bylo to, aby vytvořených stromů bylo dostatečné množství, což také bylo ověřeno<sup>106</sup>. Následně byla hledána optimální hodnota parametru *mtry*, který specifikuje počet proměnných náhodně vybraných pro účely větvení v rámci jednotlivých rozhodovacích stromů. Optimální hodnota parametru *mtry* byla hledána tak, že byly zkoušeny různé hodnoty a sledována tzv. OOB chyba (*out-of-bag error*), kterou lze chápat jako testovací chybu pro celý model. Jako finální hodnota parametru *mtry* byla vybrána hodnota 3, jelikož vedla k nejnižší hodnotě OOB chyby (konkrétně 0,245).

<sup>106</sup> Za dostatečné množství stromů bylo považováno takové, kdy přidávání dalších stromů již nevedlo k lepšímu výsledku (tj. přesnější predikce).

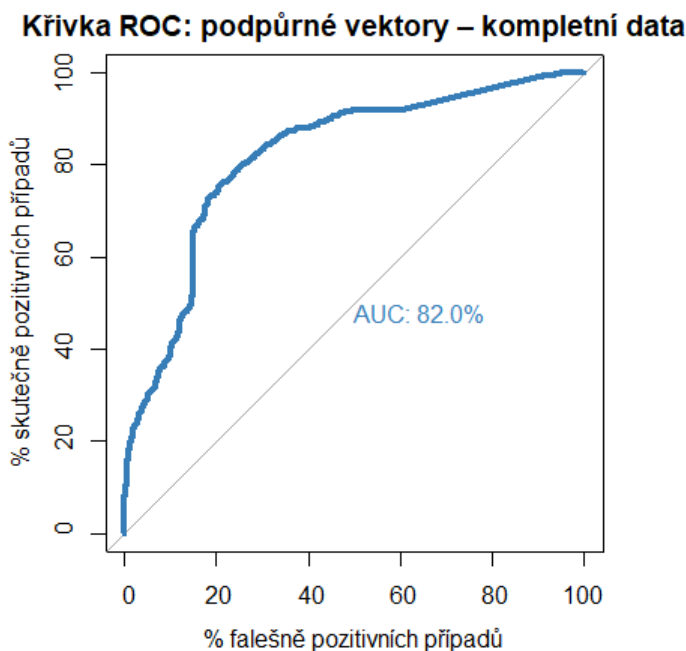


Obrázek 18: Křivka ROC při použití náhodného lesu jako klasifikačního algoritmu a kompletních dat pro účely trénování.

Predikční schopnosti finálního modelu vytvořeného pomocí náhodného lesa při použití kompletních dat byly následně posouzeny stejným způsobem jako ostatní algoritmy. Přesnost predikce se pohybuje na úrovni 75,5 %, což odpovídá jen mírnému zlepšení (1 %) oproti rozhodovacímu stromu. Senzitivita se pak v případě náhodného lesa pohybuje na úrovni 85,4 % a specifická na úrovni 58,7 %. Ve srovnání s rozhodovacím stromem tak využití náhodného lesa vedlo sice k o něco nižší senzitivě (o 3,5 %), ovšem zároveň se poměrně výrazně zvýšila specifická (o 8,6 %). Je však třeba zároveň doplnit, že při použití náhodného lesa vstupuje do výpočtu vždy prvek náhody, což ve finále vede k tomu, že při každém novém výpočtu jsou výsledné hodnoty přesnosti, senzitivity, specificity apod. mírně odlišné.

Posledním algoritmem, který byl v rámci srovnávání použit, byly tzv. **podpůrné vektory (SVM)**. V případě podpůrných vektorů byla hledána optimální hodnota parametrů *cost* a *epsilon*, přičemž pro hledání jejich optimální hodnoty jsem využil techniku vyhledávání v mřížce. Tato technika funguje tak, že vytvoří „mřížku“ z možných hodnot obou parametrů a následně vytváří model pro každou z možností na mřížce. Z vytvořených modelů je pak vybrán ten, který vede k nejlepším výsledkům. Jak je z toho popisu zřejmě patrné, technika prohledávání mřížky nemusí vždy vést k optimálnímu řešení, jelikož prohledávaná mřížka může být příliš „hrubá“ a optimální bod na ní tak nebude ležet. Z toho důvodu bylo při použití podpůrných vektorů pracováno s dostatečně „jemnou“ mřížkou. Při testování modelů

v průběhu hledání a výběru optimálních parametrů přitom byla využita metoda jednoduchého rozdělení datové sady na trénovací a validační množinu v poměru dvě třetiny na trénink a třetina na validaci.



Obrázek 19: Křivka ROC při použití podpůrných vektorů jako klasifikačního algoritmu a kompletních dat pro účely trénování algoritmu.

Co se týče predikčních schopností podpůrných vektorů při použití kompletních dat, vedl výše popsaný postup k nejlepším výsledkům. V případě přesnosti bylo dosaženo hodnoty 78,5 %, což je nejvyšší hodnota ze všech srovnávaných algoritmů. Oproti náhodnému lesu došlo ke zlepšení o 3 %, oproti baseline modelu pak dokonce o 15,5 %. Senzitivita byla v případě podpůrných vektorů druhá nejvyšší, konkrétně 87,8 %, zároveň však byla dosažena nejvyšší hodnota specifity (62,7 %). Podpůrné vektory si tak ve srovnání predikčních schopností vedly nejen celkově nejlépe, ale rovněž v případě správnosti predikce neúspěšných studentů dosahovaly nejlepších výsledků.

Na závěr této části je pro přehlednost uvedena tabulka (viz tabulka 8) uvádějící výsledky přesnosti, senzitivity, specifity a plochy pod křivkou u všech srovnávaných klasifikátorů. Jako jeden ze základních či obecných indikátorů kvality modelu se obvykle uvádí plocha pod křivkou. Podle tabulky níže je tak patrné, že logistická regrese vedla ze všech klasifikátorů k celkově nejhoršímu modelu, zatímco podpůrné vektory k modelu nejlepšímu. Stejně je tomu i v případě přesnosti a specifity. Jiná situace je pouze u senzitivity, kde dosáhl nejlepšího výsledku klasifikátor typu rozhodovací strom.

Tabulka 8: Srovnání přesnosti, senzitivity, specificity a plochy pod křivkou u analyzovaných klasifikačních algoritmů při použití kompletních dat a výchozí metody validace.

	<b>Logistická regrese</b>	<b>Rozhodovací strom</b>	<b>Náhodný les</b>	<b>Podpurné vektory</b>
Přesnost	70,6	74,5	75,5	78,5
Senzitivita	84,2	88,9	85,4	87,8
Specificita	47,4	50,1	58,7	62,7
Plocha pod křivkou (AUC)	69,8	71,9	77,2	82

#### 4.4.2. Hodnocení přínosnosti použitých prediktorů

V této části budu věnovat pozornost druhé specifické výzkumné otázce zaměřující se na to, jaké proměnné týkající se temporálních aspektů návštěvnosti blended kurzů jsou nejdůležitější při predikci úspěšnosti studentů, resp. které prediktory nevíce přispívají ke správné predikci úspěšnosti studentů. Problematika identifikace a výběru důležitých proměnných (*variable importance* či *feature selection*) je v kontextu data miningu a strojového učení řešena poměrně intenzivně již delší dobu a je k dispozici řada různých způsobů identifikace důležitých proměnných (Guyon & Elisseeff, 2003). Hlavním důvodem pro identifikaci a výběr důležitých proměnných je obvykle nutnost vybírat ze stovek či tisíců potenciálních proměnných jen určité množství prediktorů (mimo jiné z důvodu šetření časových či výpočetních nákladů). Přitom je samozřejmě cílem vybrat ty proměnné, které mají největší prediktivní sílu. V některých případech může vybírání jen určitých proměnných sloužit rovněž jako prostředek pro zlepšování predikční výkonnosti použitých algoritmů. V kontextu této sondy je hlavním cílem pro zjišťování přínosnosti jednotlivých prediktorů lepší porozumění tomu, jaké temporální charakteristiky návštěvnosti blended kurzů jsou z hlediska úspěšnosti studentů v kurzech ty nejdůležitější.

V návaznosti na předchozí část a celkové zaměření sondy A byla přitom důležitost jednotlivých prediktorů zjišťována v souvislosti se všemi čtyřmi srovnávanými klasifikačními algoritmy. Vzhledem k tomu, že každý se srovnávaných klasifikačních algoritmů funguje na jiném principu, byla i pro kvantifikaci důležitosti jednotlivých proměnných využita u každého z klasifikátorů jiná technika. V případě logistické regrese byla jako indikátor důležitosti jednotlivých proměnných využita absolutní hodnota t-statistiky pro každý z použitých prediktorů. U rozhodovacího stromu je použita specifická metrika důležitosti proměnných, která vychází z toho, nakolik se proměnná v rozhodovacím stromu objevuje v rámci jednotlivých větvení (tj. jak často proměnná v rámci stromu slouží jako kritérium rozdělení)

a nakolik svou přítomností v rozhodovacím stromu přispívá k celkovému zlepšení modelu. V případě náhodného lesa je pro výpočet důležitosti proměnných použit tzv. Giniho koeficient, konkrétně je jako indikátor důležitosti proměnné použit průměrný pokles Giniho koeficientu (*mean decrease in Gini coefficient*), který lze chápat jako mírou toho, nakolik každá proměnná přispívá k homogenitě větví a listů ve výsledném náhodném lesu (tj. v průměru napříč všemi vytvořenými stromy). V případě podpůrných vektorů zatím neexistuje široce používaný a v analytických softwarech běžně implementovaný způsob výpočtu důležitosti proměnných. Proto byl využit výpočet zmiňovaný Guyonovou a Elisseeffem (2003), který pracuje s váhou jednotlivých podpůrných vektorů.

Tabulka 9 uvádí vypočtené míry důležitosti pro jednotlivé proměnné v rámci jednotlivých klasifikačních algoritmů. Přitom se vychází z modelů, které byly prezentovány v předchozí části, tj. modelů trénovaných na kompletních datech. Vedle absolutních hodnot jednotlivých metrik důležitosti proměnných je vždy v závorce uvedena i relativní hodnota důležitosti dané proměnné. Relativní hodnotu důležitosti proměnné lze tedy chápat jako míru toho, nakolik daná proměnná v porovnání s ostatními přispívá v rámci daného klasifikátoru ke správné predikci úspěšnosti studentů v blended kurzech. Jednotlivé řádky v tabulce jsou přitom seřazeny podle důležitosti proměnných v rámci prvního klasifikátoru, tj. lineární regrese.

Z tabulky lze vidět, že při využití lineární regrese jsou nejdůležitějšími proměnnými první návštěva v kurzu a pravidelnost návštěv. Dále pak počet záznamů o aktivitě studenta v průběhu výuky a v průběhu zkouškového období a celkový čas strávený v kurzu. Zjednodušeně to můžeme interpretovat tak, že při využití logistické regrese je nejdůležitějším prediktorem úspěšnosti v kurzu to, jak brzo po začátku kurzu se student přihlásí do e-learningové podpory kurzu a jak pravidelně se do e-learningové podpory přihlašuje. Dále je pro predikci úspěšnosti studentů relativně důležité to, jak moc je student v kurzu aktivní a kolik celkového času v kurzu stráví. Naopak počty návštěv se při použití logistické regrese nejeví jako významné prediktory. Důležitost proměnných při použití rozhodovacího stromu a náhodného lesa se od logistické regrese mírně liší. Především zde má mnohem větší důležitost celkový čas strávený studentem v kurzu (v obou případech jde o nejdůležitější proměnnou) a také počet návštěv studenta v kurzu v průběhu výuky. Výrazně jiná situace je pak při použití podpůrných vektorů jakožto klasifikátoru úspěšnosti studentů. Zde patří mezi nejdůležitější proměnné počty návštěv studenta v kurzu a počty záznamů o aktivitě studenta v kurzu, a to jak v průběhu výuky, tak i v průběhu zkouškového období.

Tabulka 9: Důležitost jednotlivých proměnných v modelu u analyzovaných klasifikačních algoritmů při použití kompletních dat. Ve všech případech platí, čím větší číslo, tím větší důležitost. V závorkách jsou uvedeny relativní hodnoty důležitosti.

	<b>Logistická regrese</b>	<b>Rozhodovací strom</b>	<b>Náhodný les</b>	<b>Podpůrné vektory</b>
První návštěva kurzu	5,1 (21)	95,7 (16)	148,3 (17)	0,3 (0)
Pravidelnost návštěv	5 (21)	123 (20)	140,9 (16)	77 (7)
Počet záznamů – výuka	3,8 (16)	117,1 (19)	153,5 (17)	146 (13)
Počet záznamů – zkouškové	3,4 (14)	27,4 (5)	103,4 (12)	239,8 (22)
Celkový čas v kurzu	2,8 (12)	127,9 (21)	153,8 (18)	79,5 (7)
Počet záznamů – p. zkouškové	1,4 (6)	3,1 (1)	12,6 (1)	5,7 (1)
Počet návštěv – výuka	1 (4)	98,4 (16)	96,8 (11)	348,6 (32)
Počet návštěv – zkouškové	0,8 (3)	8,5 (1)	61,7 (7)	164,6 (15)
Počet návštěv – p. zkouškové	0,6 (3)	5,8 (1)	10,3 (1)	24,5 (2)

Z tabulky výše je patrné, že důležitost jednotlivých prediktorů se poměrně zásadně liší v závislosti na tom, jaký klasifikační algoritmus je použit. Zdá se tedy, že otázku po důležitosti jednotlivých prediktorů nelze smysluplně zodpovědět, aniž by byl zároveň zohledněn fakt, že různé klasifikační algoritmy mohou pro účely predikce preferovat odlišené prediktory.

#### **4.4.3. Predikční testování externí validací**

Poslední část sekce výsledků se zaměřuje na třetí specifickou výzkumnou otázku a na testování predikčních schopností vybraných klasifikačních algoritmů za využití externí validace. Jak již bylo nastíněno v rámci postupu analýzy dat (část 4.3.4.), predikční testování externí validací bylo provedeno dvakrát, přičemž poprvé probíhalo rozdělení dat na trénovací a testovací množinu náhodně<sup>107</sup>, zatímco podruhé byla při náhodném výběru navíc reflektována úroveň kurzu. Všichni studenti z jednoho kurzu tak museli být buď v trénovací, nebo v testovací množině, ale nikoli v obou (tj. nemohlo se stát, aby část studentů jednoho kurzu byla v trénovací množině a část v testovací množině). Tento způsob testování predikčních schopností vybraných klasifikátorů pomocí externí validace mi umožnil v prvním kroku ověřit, nakolik jsou predikční schopnosti klasifikátorů prezentované v části 4.4.1.

<sup>107</sup> Ovšem při zachování proporčního zastoupení úspěšných a neúspěšných studentů (tj. závisle proměnné) v trénovací i testovací množině.

platné i při testování modelů na zcela nových případech. V druhém kroku pak testování externí validací umožní zjistit, nakolik jsou analyzované klasifikátory schopny natrénovat se na datech z určité sady kurzů a následně správně klasifikovat úspěšnost studentů ve zcela jiných kurzech.

Tabulka 10 prezentuje výsledky predikčního testování externí validací za všechny čtyři analyzované algoritmy. Připomeňme, že šlo o externí validaci se 100 opakováními, tzn., že celkem stokrát byla kompletní datová sada rozdělena na trénovací a testovací část v poměru dvě třetiny na trénink a třetina na testování, a následně bylo výše popsaným postupem vytvořeno 100 různých modelů, které byly vyhodnoceny skrze přesnost, senzitivitu, specifickost a plochu pod křivkou. Z této stovky modelů pak byl v rámci každého klasifikačního algoritmu spočítán průměr a směrodatná odchylka pro každou z hodnotících metrik, jak je patrné z tabulky níže. Při srovnání s tabulkou 8 je patrné, že predikční schopnosti logistické regrese a náhodného lesa se výrazně nezměnily. V případě logistické regrese došlo ke snížení přesnosti o 0,5 % (AUC rovněž o 0,5 %) a v případě náhodného lesa byla snížena přesnost o 1,4 % (AUC o 1,4 %). U rozhodovacího stromu je již rozdíl výraznější, jelikož přesnost klesla o 2,9 % a AUC o 4,1 %. Snížení predikčních schopností u podpůrných vektorů lze pak již považovat za zásadní. Přesnost je zde nižší o 6,5 % a AUC o 9,3 %. Z toho lze usoudit, že při využití podpůrných vektorů pro vytvoření modelu prezentovaného v části 4.1.1. došlo k výraznému nadhodnocení predikčních schopností. I přesto si ale podpůrné vektory (a ostatně i zbývající klasifikátory) udržely relativně dobré predikční schopnosti při srovnání s výchozím modelem.

*Tabulka 10: Srovnání přesnosti, senzitivity, specifickosti a plochy pod křivkou u analyzovaných klasifikačních algoritmů při použití externí validace se 100 opakováními (bez zohlednění úrovně kurzů).*

	<b>Logistická regrese</b>		<b>Rozhodovací strom</b>		<b>Náhodný les</b>		<b>Podpůrné vektory</b>	
	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>
Přesnost	70,1	1,4	71,6	1,4	74,1	1,3	72	1,5
Senzitivita	83,1	2,1	85,8	2,7	84,5	1,5	83,8	1,9
Specifickost	48	3,6	47,2	5,1	56,5	2,8	51,8	4,3
Plocha pod křivkou (AUC)	69,3	1,8	67,8	2,5	75,8	1,3	72,7	1,6



Tabulka 11 prezentuje výsledky predikčního testování externí validací při zohlednění úrovně kurzů. Zde je již na první pohled zřejmé, že je situace výrazně jiná a že všechny klasifikátory mají výrazně horší predikční schopnosti. V případě rozhodovacího stromu, náhodného lesa a podpůrných vektorů je pak přesnost dokonce horší než u baseline modelu, což v praxi znamená naprostou nepoužitelnost takových modelů. Logistická regrese si sice udržela vyšší přesnost než baseline model, ale pouze o 3,1 %, což nelze považovat za výrazné zlepšení. Z těchto výsledků tak lze usoudit, že s výjimkou logistické regrese mají analyzované klasifikační algoritmy výrazný problém predikovat úspěšnost studentů ve zcela nových kurzech (tj. kurzech, které nebyly součástí trénovací množiny).

Výrazně větší směrodatné odchylky oproti předchozí tabulce zároveň znamenají, že při zohlednění úrovně kurzů dochází k tvorbě výrazně různorodějších modelů, co se týče jejich predikčních schopností. Tzn., že z vytvořené stovky modelů sice některé dosahovaly relativně dobrých výsledků, ale některé (většina) naopak měly výrazně špatné výsledky. To naznačuje, že z hlediska dvouúrovňového charakteru dat dochází k tzv. přeučování modelů (*overfitting*), kdy jsou klasifikační algoritmy příliš přizpůsobeny kurzům v trénovací sadě dat, a nejsou tak schopny dostatečně zobecňovat a predikovat úspěšnost studentů v kurzech v testovací množině. Relativní úspěšnost logistické regrese při predikčním testování externí validací zohledňující úroveň kurzů je pak zřejmě dána tím, že jde o poměrně jednoduchý klasifikátor, který je tím pádem odolný vůči přeučení.

Tabulka 11: Srovnání přesnosti, senzitivity, specificity a plochy pod křivkou u analyzovaných klasifikačních algoritmů při použití externí validace se 100 opakováními zohledňující úroveň kurzů.

	Logistická regrese		Rozhodovací strom		Náhodný les		Podpůrné vektory	
	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>	<i>M</i>	<i>SD</i>
Přesnost	66,1	5,4	61,6	6,2	59,2	5	61,3	5,7
Senzitivita	81,7	7,1	72,2	11,7	67,2	9,2	71,3	9,4
Specifická	40,1	9,4	46,2	9	48	7,5	46,8	9,2
Plocha pod křivkou (AUC)	60,4	7,6	56,1	6,4	57,9	5,5	57,6	6,1

## 4.5. Diskuze a závěr sondy A

Cílem výzkumné sondy A bylo zhodnotit, jaké jsou možnosti využití vybraných klasifikačních algoritmů pro účely predikce úspěšnosti studentů blended kurzů, a to pouze na základě vybraných temporálních ukazatelů návštěvnosti studentů v LMS. Prozaicky řečeno:

Nakolik lze vůbec predikovat úspěšnost v kontextu blended learningu, při kterém se pouze větší či menší část výuky odehrává v LMS? Nakolik lze predikovat úspěšnost studentů pouze na základě toho, jak navštěvují kurz v LMS? A jak si při predikci vedou různé klasifikační algoritmy?

Oproti dosavadním výzkumům v této oblasti přitom bylo pro účely analýz využito výrazně větší množství různých blended kurzů, a tudíž bylo možné věnovat pozornost rovněž obecnější otázce zobecnitelnosti a přenositelnosti prediktivních modelů v kontextu blended learningu. Výsledky sondy tak přináší důležité poznatky k současným možnostem predikce úspěšnosti studentů v blended learningu za využití obecných prediktivních modelů.

#### **4.5.1. Shrnutí odpovědí na stanovené výzkumné otázky**

První specifická výzkumná otázka se zaměřovala na základní posouzení predikčních schopností zvolených klasifikačních algoritmů (logistická regrese, rozhodovací strom, náhodný les, podpůrné vektory), přičemž toto posouzení proběhlo za využití dat ze všech analyzovaných kurzů. Nejlepšího výsledku dosáhl algoritmus podpůrných vektorů, který byl schopen v 78,5 % případů správně predikovat úspěšnost či neúspěšnost studenta v blended kurzu na základě temporálních charakteristik návštěvnosti. To je o 15,5 % více než v případě tzv. baseline modelu, což lze považovat za výrazné zlepšení.<sup>108</sup> Nejhoršího výsledku bylo dosaženo za využití logistické regrese (přesnost 70,6 %). U všech klasifikačních algoritmů však docházelo k tomu, že byly mnohem lepší v predikci úspěšných studentů než v predikci neúspěšných studentů. Například algoritmus podpůrných vektorů byl schopen správně predikovat 87,8 % úspěšných studentů, ale pouze 62,7 % neúspěšných studentů. V případě logistické regrese pak dokonce docházelo ke správné predikci neúspěšných studentů pouze v 47,4 % případů. To naznačuje, že v případě praktické aplikace specificky pro účely identifikace rizikových studentů je třeba počítat s výrazně nižší mírou úspěšné predikce.

Druhá specifická výzkumná otázka se věnovala tomu, jaké z použitých prediktorů založených na temporálních aspektech návštěvnosti blended kurzů nejvíce přispívají k predikci úspěšnosti studentů. Výsledky analýzy ukazují, že míra přínosnosti jednotlivých prediktorů se výrazně liší v závislosti na použitých klasifikačních algoritmech. V případě logistické regrese patřilo mezi nejdůležitější faktory to, jak brzo po začátku kurzu se student poprvé přihlásil do kurzu a jak pravidelně poté kurz navštěvoval. Mezi relativně silné prediktory pak spadal rovněž celkový počet záznamů o aktivitě studenta v kurzu v průběhu

---

<sup>108</sup> Je třeba si uvědomit, že je v této sondě záměrně omezen počet prediktorů. V případě praktické aplikace by samozřejmě došlo k využití většího množství prediktorů, a tudíž by se s největší pravděpodobností dospělo k ještě vyšší přesnosti v predikci úspěšnosti studentů.

výuky a v průběhu zkouškového období a také celkový čas strávený prací v kurzu. Naopak počty návštěv v případě logistické regrese nesehrávaly významnější roli. Tak tomu ale nebylo u ostatních klasifikačních algoritmů, kde byl naopak počet návštěv v průběhu výuky relativně důležitým (v případě rozhodovacího stromu a náhodného lesu) či dokonce jednoznačně nejdůležitějším prediktorem (v případě podpůrných vektorů). Algoritmus podpůrných vektorů pak dává celkově velmi odlišný obraz oproti logistické regresi. První přihlášení do kurzu a pravidelnost v navštěvování kurzu sehrává u tohoto algoritmu jen velmi malou roli. Do značné míry jediným výsledkem, na kterém se v tomto ohledu shodují všechny klasifikační algoritmy, je nepříznost počtu návštěv a počtu záznamů o aktivitě v průběhu prodlouženého zkouškového období jakožto prediktora úspěšnosti. Zřejmě tedy aktivita studenta v průběhu prodlouženého zkouškového období obvykle na výsledném hodnocení už nic nemění, anebo je takových případů příliš malé množství na to, aby to sehrálo při predikci úspěšnosti významnější roli.

Nutno zároveň zdůraznit, že výše uvedené výsledky analýzy související s druhou výzkumnou otázkou otevírají nové a, jak se domnívám, poměrně zásadní téma. Dosavadní studie, které v souvislosti s predikcí úspěšnosti studentů věnovaly pozornost srovnávání různých klasifikačních algoritmů (např. Romero, Espejo, Zafra, Romero, & Ventura, 2013; Romero, López, Luna, & Ventura, 2013; Sheshadri, Gitinabard, Lynch, Barnes, & Heckman, 2018; Zafra, Romero, & Ventura, 2011), se zaměřovaly primárně na srovnávání klasifikačních algoritmů z hlediska jejich predikčních schopností, resp. z hlediska míry úspěšnosti predikce, které jsou schopny dosáhnout. Zatím však nebyl akcentován fakt, že se jednotlivé klasifikační algoritmy neliší pouze tím, nakolik jsou schopny správně predikovat úspěšnost studentů, ale také tím, jaké k tomu využívají proměnné. To je ovšem zcela zásadní a věcně možná i důležitější než případné dílčí odlišnosti v prediktivních schopnostech. Znamená to totiž, že otázka po tom, které faktory související s výukou a učením v (blended) kurzech v LMS jsou důležité z hlediska predikce úspěšnosti studentů, se výrazně komplikuje. Klasifikační algoritmy různých typů totiž mohou upřednostňovat zcela odlišné prediktory, a to až do takové míry, že jeden a týž prediktor může být při použití určitého klasifikačního algoritmu vyhodnocen jako zcela nepodstatný, zatímco při využití jiného algoritmu by byl tím nejdůležitějším prediktorem (jako tomu bylo u proměnné *První návštěva kurzu* a algoritmu podpůrných vektorů ve srovnání s logistickou regresí).

V rámci třetí výzkumné otázky jsem přesunul pozornost k problematice přenositelnosti či zobecnitelnosti prediktivních modelů, resp. k tomu, nakolik je možné pro účely predikce úspěšnosti studentů v blended kurzech vytvořit obecný prediktivní model, který by byl schopen predikce napříč různými kurzy. Pro zodpovězení této otázky bylo využito predikční

testování externí validací a bylo hodnoceno, nakolik se tím změní míra úspěšné predikce. Nejprve jsem přistoupil k predikčnímu testování externí validací bez zohledňování úrovně kurzů. U většiny algoritmů došlo v tomto kroku spíše k nepatrnému či malému zhoršení predikčních schopností. Ovšem v případě algoritmu podpůrných vektorů již došlo k relativně výraznému zhoršení (o 6,5 % nižší přesnost, o 9,3 % nižší AUC), což znamená, že při základním posuzování predikčních vlastností v rámci první výzkumné otázky došlo u podpůrných vektorů k nadhodnocení predikčních schopností.

V druhém kroku jsem pak přistoupil k predikčnímu testování externí validací při zohlednění úrovně kurzů, čili klasifikační algoritmy byly trénovány na jiné množině kurzů, než na které byly následně testovány predikční schopnosti výsledných klasifikačních modelů. To dovoluje zhodnotit, nakolik jsou jednotlivé klasifikační algoritmy schopné dospět k dostatečně obecnému modelu, který by fungoval napříč různými blended kurzy. Výsledky tohoto predikčního testování přitom odhalily neschopnost většiny klasifikačních algoritmů dospět k dostatečně obecnému modelu. Algoritmy rozhodovacího stromu, náhodného lesa i podpůrných vektorů dospěly v přesnosti predikce k horším výsledkům, než tzv. baseline model. Jen logistická regrese dospěla k vyšší přesnosti než baseline model, ovšem pouze o 3,1 %, což zřejmě bude dáno relativní jednoduchostí logistické regrese v porovnání s ostatními algoritmy. Jak uvádí Baker a Inventado (2014), konzervativní algoritmy jako logistická regrese mohou ve vzdělávacím kontextu dosahovat lepších výsledků, kvůli poměrně velké míře šumu v analyzovaných datech. V rámci predikčního testování externí validací zohledňující úroveň kurzů tak zřejmě došlo k tomu, že pokročilejší algoritmy nebyly schopny v trénovacích datech dostatečně odlišit signál od šumu, resp. nebyly schopny odlišit obecné charakteristiky související s úspěšností studentů v kurzech, a tudíž nebyly schopny generovat dostatečně obecný model, který by byl funkční i na jiných kurzech obsažených v testovací množině.

#### **4.5.2. Důsledky pro praxi a další výzkum**

Z výše uvedených výsledků plyne několik zásadních důsledků jak pro praxi, tak pro další výzkum v oblasti analytiky učení a data miningu ve vzdělávání. Předně se ukazuje, že je na místě určitá skepse, co se týče dosavadních prediktivních řešení a obecně možností predikce úspěšnosti studentů v blended kurzech. Přestože je oblast predikce úspěšnosti a identifikace rizikových studentů jednou z nejvíce akcentovaných výzkumných oblastí data miningu ve vzdělávání i analytiky učení, výsledky této sondy naznačují, že přinejmenším v kontextu blended kurzů probíhajících v systémech typu LMS jsme zatím stále poměrně daleko od prakticky využitelného obecného prediktivního systému, který by byl schopen s dostatečnou

mírou přesnosti predikovat úspěšnost studentů či včas identifikovat studenty s rizikem nedokončení napříč různými kurzy. Je otázkou, nakolik lze souhlasit s názvem studie Gaševiče et al. (2016), který naznačuje, že snahy o obecný prediktivní model možná nemusí být tím nejvhodnějším a nejpřínosnějším cílem. Rozhodně lze však souhlasit s výzvou k opatrnosti, kterou uvedení autoři směřují ke vzdělávacím institucím. Investice do komerčních řešení nabízejících fungující a zároveň obecný systém pro predikci úspěšnosti v LMS zřejmě prozatím nebude dobrou volbou. Nadále také platí výzva, o které hovořili již Gaševič, Dawson a Siemens (2015). Ti považovali za naprosto nezbytné zaměřit se na realizaci evaluačních studií, které by využívaly data z širokého spektra různých kurzů a dovolovaly tak získat lepší představu o zobecnitelnosti a přenositelnosti jednotlivých řešení a modelů.

Z dosavadních výsledků výzkumu i z výsledků této sondy je zároveň patrných několik možností rozvoje, kterým stojí za to věnovat pozornost v nadcházejícím výzkumu. Základním problémem či otázkou je to, jakým způsobem při modelování zohlednit výrazné odlišnosti mezi různými kurzy. Jednou z možných cest by bylo neusilovat o obecný prediktivní model, nýbrž vytvářet specifické modely pro každý kurz zvlášť. Tzn. usilovat pouze o predikci úspěšnosti studentů v určitém kurzu na základě dat z dřívějších běhů toho stejného kurzu. Ani zde však zatím není zřejmé, nakolik by byly takové dílčí modely úspěšné. Navíc by to samozřejmě znemožňovalo využít prediktivní systém pro zcela nový kurz (tj. pro takový, pro který ještě neexistují data z předchozích běhů). Je také otázkou, jakým způsobem by do takového řešení vstupovaly průběžné úpravy kurzu či změny ve způsobu jeho vedení. Lze totiž předpokládat, že jakákoli výraznější změna kurzu by vedla ke snížení prediktivních schopností modelu, který byl učen na datech z předchozích běhů kurzu.

Druhou z možných cest je pokračovat ve snahách o obecný prediktivní model. V takovém případě pak musí výzkumné snahy směřovat k tomu, jak při modelování zachytit a zužitkovat informace na úrovni kurzů. Prvním krokem by mohlo být využití proměnných, které by byly agregované na úrovni kurzů (tj. např. průměrný počet návštěv studentů v kurzu, průměrný čas trávený studenty v daném kurzu apod.). Případně využít jiné typy prediktorů na úrovni kurzů a jiné prediktory naopak na úrovni jednotlivých studentů. Např. použít četnosti využívání různých typů nástrojů v LMS jakožto prediktory na úrovni kurzů (což by mohlo zachytit odlišnosti mezi různými typy kurzů), zatímco na úrovni studentů pracovat s temporálními charakteristikami návštěvnosti. Jiným přístupem, který by mohl vést k lepším predikčním schopnostem, by byla kombinace shlukování a klasifikace ve smyslu tzv. *cluster-then-predict* přístupu. V takovém případě je na datech nejprve aplikováno shlukování, jehož výsledky se stanou součástí dat, na kterých je následně realizována klasifikace. Takový přístup by mohl napomoci k identifikaci různých shluků či skupin

vzájemně podobných kurzů, v rámci kterých by tudíž mohly platit obdobné vztahy mezi použitými prediktory a úspěšností studentů. V neposlední řadě se nabízí využití ještě pokročilejších klasifikačních algoritmů, jako jsou např. umělé neuronové sítě (viz např. Monllao Olivé, Huynh, Reynolds, Dougiamas, & Wiese, 2019), případně rozvíjení existujících klasifikačních algoritmů takovým způsobem, aby byly schopny lépe pracovat s daty víceúrovňové povahy (viz např. Hajjem, Bellavance, & Larocque, 2014; Lin & Luo, 2019; Speiser et al., 2018).

## 5. Sonda B - Analýza interakce studentů a učitelů v online diskuzních fórech s využitím analýzy sociálních sítí<sup>109</sup>

Online diskuzní fóra jakožto asi nejčastěji využívaný typ nástrojů pro komunikaci a interakci v online kurzech jsou nedílnou součástí systémů pro řízení výuky (LMS), kde právě nástroje pro komunikaci a spolupráci tvoří jednu z pěti základních kategorií integrativních vzdělávacích technologií (viz 1.2.2. *Systémy pro řízení výuky*). Podobně je komunikace a interakce mezi studenty vnímána jako jeden z důležitých prvků vzdělávání a výuky v online prostředí, a to zvláště v těch případech, kdy tvůrci online vzdělávání vychází ze (sociálně-)konstruktivistického paradigmatu. Vzájemná komunikace mezi studenty v rámci online kurzu tak může nejen nahrazovat či alespoň zmírňovat chybějící přímý kontakt, nýbrž také může sehrávat důležitou roli při sdílení znalostí a zkušeností mezi studenty, spolupráci při řešení zadaných úkolů, aktivním zapojení studentů do učící se komunity apod. (Gao, 2014; Tirado, Hernando, & Aguaded, 2015; Wise, Hausknecht, & Zhao, 2014).

Není proto překvapivé, že se této problematice věnuje v kontextu e-learningu relativně velká výzkumná pozornost. Stejně tak v kontextu analytiky učení a data miningu ve vzdělávání je problematika interakce studentů v online diskuzních fórech jedním z řešených témat, a to zvláště v rámci tzv. sociální analytiky učení (viz 2.3.5. *Sociální analytika učení*). Existují přitom různé způsoby, jakými výzkumníci přistupují ke studiu komunikace a interakce v diskuzních fórech, a to od ryze kvantitativních, přes smíšené, až po ryze kvalitativní přístupy (srov. Haythornthwaite, de Laat, & Schreurs, 2016; Wise & Paulus, 2016). I přes různorodost použitých výzkumných přístupů a mnohdy i různorodost zjištěných výsledků je však v současnosti poměrně zřejmé, že interakce v online diskuzních fórech je komplexním fenoménem, který není možné dostatečně plně zkoumat pouze jednoduchými kvantitativními postupy. Metriky jako počet přístupů do diskuzního fóra, počet diskuzních příspěvků či počet odstartovaných diskuzí nejen že podávají jen velmi kusý obraz o situaci v diskuzním fóru, nýbrž mohou být dokonce značně zkreslující a zavádějící (srov. Burgerová & Adamkovičová, 2014). Jak uvádí Wise a Paulus (2016), v současnosti již takové příliš zjednodušující míry participace v online diskuzních fórech nelze považovat za dostatečné pro porozumění interakci studentů a jejich učení.

---

<sup>109</sup> Průběžné výsledky této sondy byly podkladem pro prezentaci autora na mezinárodní konferenci ECER (Juhaňák & Zounek, 2015).

I proto se v oblasti kvantitativně orientovaných výzkumných přístupů rozvíjí stále nové a sofistikovanější přístupy pro zkoumání interakce studentů v online diskuzích. Jedním z relativně populárních a zároveň slibných metodologických přístupů je analýza sociálních sítí (*social network analysis – SNA*), kterou využívá stále více výzkumníků (např. Joksimović et al., 2016; Kellogg, Booth, & Oliver, 2014; Wise & Cui, 2018; Zhang, Skryabin, & Song, 2016) a která nabízí poměrně široké možnosti pokročilé kvantitativní analýzy interakce v online diskuzích.

Dosavadní poznání o interakci studentů v online diskuzních fórech však stále zůstává relativně omezené, a to tím spíše, upřeme-li pozornost primárně na systémy pro řízení výuky a jejich používání v kontextu *blended learningu*, což odpovídá zaměření této práce. Především v posledních letech totiž využití analýzy sociálních sítí převažuje spíše v souvislosti s online kurzy a zvláště pak s kurzy typu MOOC (tj. otevřené online kurzy určené pro velmi velké množství účastníků). Dalším výrazným limitem dosavadního výzkumu v této oblasti je pak to, že se realizované studie obvykle zaměřují jen na velmi malé množství kurzů, což nutně poskytuje pouze velmi omezený obrázek o způsobech interakce studentů v online diskuzních fórech. Sondou B se snažím reagovat především na tyto dva základní limity, proto využívám analýzu sociálních sítí pro zkoumání interakce studentů a učitelů v online diskuzních fórech jednak v rámci spíše menších kurzů, jednak napříč širokým spektrem různých online a *blended* kurzů. To by mělo poskytnout mnohem širší přehled o existujících formách interakce v diskuzních fórech v LMS a rozšířit tak dosavadní poznání v této oblasti.

## 5.1. Přehled dosavadních výzkumů k sondě B

Problematika učení prostřednictvím online diskuzí tvoří poměrně rozsáhlou oblast pedagogického výzkumu. Jak upozorňují Wiseová a Paulusová (2016), lidé se mohou v online prostředí zapojovat do diskuzí v mnoha různých kontextech a mnoha různými způsoby. Diskuze může probíhat v rámci samostatně fungujících diskuzních fór, ale třeba také v nástrojích pro okamžitou komunikaci (tzv. *instant messaging*). Diskuze se mohou rozvíjet např. pod články na stránkách zpravodajských deníků, ale také na sociálních sítích jako Facebook či Twitter, či k nim mohou být využívány blogy (viz Zounek et al., 2016). Všechny takové diskuze přitom mohou být z hlediska pedagogického výzkumu v určitém ohledu zajímavé, protože v nich může docházet k nějaké formě učení (ať už záměrného či nezáměrného). Přesto, některé z online diskuzí jsou v kontextu pedagogického výzkumu,



a zvláště v oblasti e-learningu, akcentovány výrazně více než jiné. Pro základní orientaci v této problematice, je však nutné nejprve provést alespoň tři výchozí rozlišení<sup>110</sup>:

- **Online diskuze v kontextu formálního, neformálního a informálního vzdělávání.** V prvním kroku je třeba odlišit běžné každodenní online diskuze, které nemají primárně vzdělávací charakter, ale v rámci kterých může docházet k neplánovanému spontánnímu učení. V druhém kroku je pak vhodné rozlišit také online diskuze v kontextu formálního a neformálního vzdělávání, jelikož v rámci formálního vzdělávání mohou mít online diskuze často poněkud jiný charakter než v případě neformálního vzdělávání (např. povinná účast, specifické zadání, průběžná facilitace apod.)<sup>111</sup>.
- **Synchronní versus asynchronní online diskuze.** Diskuze mohou v online prostředí probíhat synchronně, tj. takovým způsobem, kdy jsou všichni diskutující zapojeni do diskuze ve stejném čase a reakce na jednotlivé diskuzní příspěvky se tak objevují okamžitě. Typickým příkladem jsou výše zmiňované nástroje pro okamžitou komunikaci (tzv. *instant messaging* – v současnosti např. aplikace jako *WhatsApp*, *Viber*, *Facebook Messenger* apod.), spadají sem ale i případné nástroje a služby pro online chaty. Na druhé straně mohou diskuze probíhat tak, že účastníci diskuze nekomunikují ve stejném čase, nýbrž každý z účastníků se do diskuze zapojuje v jiný čas. Typickým příkladem takových diskuzí jsou právě online diskuzní fóra.
- **Text versus audio či video jakožto prostředek komunikace v rámci online diskuze.** V neposlední řadě je třeba rozlišovat mezi tím, když online diskuze probíhá prostřednictvím textu, což je asi nejčastější případ, a když naopak probíhá prostřednictvím audio či video přenosu. Většina nástrojů pro okamžitou komunikaci jako zmiňovaný *WhatsApp* či *Viber* přitom v současnosti umožňují nejen textovou komunikaci, ale i audio a video přenos.

---

<sup>110</sup> Samozřejmě by bylo možné doplnit řadu dalších relevantních a důležitých rozlišení jako např. to, zda je součástí diskuze moderátor či administrátor (Zounek et al., 2016), nebo jak velkou skupinou účastníků je diskuze tvořena (Wise & Paulus, 2016). Pro účely základního vymezení problému však považuji za dostačující tři níže uvedené distinkce.

<sup>111</sup> Jak uvádí např. Zhangová, Skryabin a Song (2016), v kontextu kurzů typu MOOC, které lze vnímat jako součást neformálního vzdělávání, jsou online diskuzní fóra obvykle volitelným (nepovinným), otevřeným a jen volně strukturovaným diskuzním prostředím.

Oblast, které je v kontextu e-learningu věnována asi největší výzkumná pozornost, můžeme tudíž s oporou o výše naznačené distinkce vymezit jako asynchronní textové diskuze probíhající v online či blended kurzech (obvykle v rámci nějakého systému typu LMS) realizovaných zpravidla v kontextu formálního vzdělávání (Gao, 2014; Tirado-Morueta, Maraver-López, & Hernando-Gómez, 2017; Wise & Paulus, 2016).

Co se týče vymezení asynchronních online diskuzních fór v LMS, jde o nástroje mající podobu webové stránky, na níž účastníci vkládají své názory či reakce (Arulchelvan, 2011; Zounek et al., 2016). Ty vkládají v podobě diskuzních příspěvků (*posts*), které jsou sdružované do samostatných sekcí či celků obvykle označovaných jako diskuzní vlákna (*discussion threads*). Diskuzní příspěvky v rámci vlákna bývají nejčastěji zobrazovány chronologicky od nejstarších po nejnovější a zpravidla je také zohledňována stromová struktura příspěvků, tj. rozlišení toho, zda jde o reakci na již existující příspěvek. Součástí příspěvků jsou pak obvykle také doplňující informace o příspěvateli (tj. kdo příspěvek vložil – nejčastěji jméno, případně přezdívka) a vložení příspěvku (především čas vložení).

Většina odborníků v oblasti e-learningu se přitom shoduje na tom, že interakce a participace studentů v online diskuzích a diskuzních fórech je jednou ze stěžejních součástí učení a výuky prostřednictvím systémů typu LMS (srov. např. Fidalgo & Thormann, 2012; Hrastinski, 2008, 2009; Thomas, 2013; Wise, Hausknecht, & Zhao, 2014; Wise & Paulus, 2016). Mimo jiné především proto, že využívání online diskuzních fór má potenciál generovat vysoké množství interakcí, a to ať již jde o interakce od studenta ke studentovi, od studenta k učiteli či od učitele ke studentovi (Tirado, Hernando, & Aguaded, 2015). A právě tyto interakce jsou prostorem, který dává příležitost k učení a tvorbě znalostí. I proto Gao (2014) uvádí, že asynchronní online diskuze se staly jedním z hlavních prostředků podpory učení studentů v online prostředí, jelikož mohou poskytovat ideální prostředí pro (sociálně-)konstruktivistický způsob výuky a učení.

### **5.1.1. Participace studentů v online diskuzích a její výzkum**

Přestože je výzkum problematiky učení prostřednictvím online diskuzí velmi širokou oblastí zaměřující se na nejrůznější aspekty tohoto fenoménu, jedním z dominantních témat jsou právě otázky spojené s mírou participace studentů v diskuzních fórech. Například Hrastinski (2008) ve své přehledové studii hovoří až o šesti různých způsobech, jakými bývá konceptualizována participace studentů v kontextu e-learningu a online učení. A zatímco na první a nejzákladnější úrovni je za participaci považován pouhý přístup studenta do e-learningového prostředí či přímo do diskuzního fóra, teprve na šestém a nejvyšším stupni

je participace studenta v diskuzním fóru vnímána tak, že se student stává účastníkem opravdového dialogu.

Specificky v kontextu participace v asynchronních diskuzních fórech pak Knowlton (2005) rozlišuje pět různých forem participace:

- **Pasivní** (*Passive*) participace je dle Knowltona nezákladnější formou participace. Jde o situaci, kdy diskuzní fórum není vnímáno jako prostředek interakce mezi studenty, ale spíše je prostředek přenosu informací a znalostí od učitele ke studentům.
- **Rozvojová** (*Developmental*) participace odkazuje k chápání online diskuze primárně jakožto místa, ve kterém dochází k sociálně orientované komunikaci a budování komunity. Interakce mezi účastníky může být v tomto kontextu poměrně vysoká, obvykle se však nezaměřuje na věcnou stránku či obsah kurzu, a tudíž v ní jen ojediněle dochází k učení.
- **Generativní** (*Generative*) participace je úrovní, ve které je již diskuzní fórum vnímáno jako prostor, kde má docházet k učení a budování znalostí, ovšem tento proces je chápán jako individuální a soukromý. Interakce v diskuzním fóru tak obvykle probíhá především jakožto reakce na zadání či příspěvky vyučujícího, přičemž příspěvkům ostatních studentů není věnována větší pozornost.
- **Dialogická** (*Dialogical*) participace již patří k vyšším úrovním zapojení studentů do online diskuze. Podobně jako v případě rozvojové participace je fórum chápáno jako prostor pro interakci mezi studenty navzájem, ovšem komunikace mezi studenty již nemá pouze socializační charakter, nýbrž dochází k věcné diskuzi zahrnující analýzu dosavadní diskuze, formulaci vlastního stanoviska, syntézu více diskuzních příspěvků do jednoho celku apod.
- **Metakognitivní** (*Metacognitive*) participace je dle Knowltona poslední a nejvyšší formou zapojení studentů do online diskuze. Na této úrovni se studenti nejen zapojují do dialogického procesu (jako v případě předchozí úrovně), nýbrž navíc tento proces dále reflektují. Věnují tak pozornost např. svému vlastnímu porozumění diskutovanému problému, vývoji svého uvažování o problému v průběhu diskuze, roli ostatních účastníků diskuze a jejich vlivu na vlastní porozumění problému apod.

Jiný pohled na participaci se zaměřuje na typy účastníků diskuze. Nandi, Hamiltonová a Harland (2012), kteří navazují na Dennenovou (2005; 2008) a další autory hovoří

v souvislosti s participací v online diskuzích o tzv. *lurkers*<sup>112</sup>. Tímto termínem bývají označováni takoví účastníci diskuze, kteří sice vstupují do diskuzního fóra a čtou příspěvky ostatních, ale sami se do diskuze aktivně nezapojují a nepřidávají vlastní příspěvky. Vedle těchto *lurkers* pak Nandi, Hamiltonová a Harland hovoří ještě o dvou skupinách účastníků participujících v online diskuzních fórech. Odlišují přitom na jedné straně účastníky, kteří vnímají diskuzní fórum spíše jako nástěnku, kam sice vkládají své vlastní příspěvky, ale jen ojediněle se zapojují do interakce s ostatními diskutujícími. Na druhé straně jsou pak dle uvedených autorů ti účastníci, kteří využívají diskuzní fóra v plném rozsahu.

Někteří autoři však považují pojem *lurkers* za problematický. Například Wiseová, Hausknechtová a Zhaoová (2014) upozorňují, že tento pojem má často negativní konotace, protože je chápán jako označení někoho, kdo se do diskuze nijak aktivně nezapojuje, a tudíž pro diskuzi není žádným přínosem. Takové pojetí je však podle uvedených autorek zavádějící, jelikož vychází z předpokladu, že věnování pozornosti příspěvkům ostatních účastníků je pasivní aktivitou s nízkou kognitivní náročností, což mnohdy nemusí být pravda. Navíc dle autorek pojem *lurkers* odděluje proces sledování a čtení příspěvků od tvorby příspěvků a ignoruje tak vzájemnou provázanost obou těchto procesů.

Autorky Wiseová, Hausknechtová a Zhaoová (2014) však kontextu online diskuzí záměrně nepoužívají pojem „čtení“ (*reading*), přestože je řeč o diskuzních příspěvcích textového charakteru. Jsou totiž přesvědčeny, že vzhledem k povaze textu v online diskuzích jsou při jeho čtení zapojeny jiné kognitivní procesy než při čtení např. knihy. Podobně jako v rámci běžné komunikace tak raději hovoří o „mluvení“ (*speaking*), čímž myslí tvorbu diskuzních příspěvků, a o „poslouchání“ (*listening*), čímž označují obecně přístup k diskuzním příspěvkům (*accessing existing posts*). Na základě svých předchozích studií pak odlišují čtyři různé způsoby, jakými účastníci diskuze přistupují k příspěvkům ostatních (autorky zde hovoří o tzv. *listening patterns*), a to podle toho, jak velkému množství příspěvků věnují pozornost a zda se jim věnují pouze povrchově, nebo jimi tráví výraznější množství času<sup>113</sup>.

Co se pak týče výzkumných metod využívaných při výzkumu učení prostřednictvím online diskuzí, užitečný přehled nabízí Wiseová a Paulusová (2016), které v prvním kroku rozlišují

---

<sup>112</sup> V českém kontextu neexistuje zavedený překlad.

<sup>113</sup> Konkrétně autorky hovoří o: 1) účastnících, kteří obecně věnují jen velmi málo pozornosti příspěvkům ostatních diskutujících a celkově si jich „přečtou“ jen velmi málo (*disregardful*), 2) účastnících, kteří projdou velké množství příspěvků, ale netráví jejich „čtením“ velké množství času (*coverage*), 3) účastnících, kteří prochází omezené množství příspěvků, ale věnují jejich studiu relativně velkou pozornost (*focused*) a 4) účastnících, kteří prochází velké množství příspěvků a zároveň tráví značné množství času jejich podrobným studiem (*thorough*).

inferenční metody (*inferential methods*) a interpretativní metody (*interpretive methods*).<sup>114</sup> Inferenční metody přitom spočívají především v analýze kvantitativních dat, zatímco interpretativní metody se naopak zaměřují na data kvalitativního charakteru. V rámci interpretativních metod přitom autorky rozlišují induktivní tematickou analýzu (*inductive thematic analysis*) a přístupy zaměřující se na jazyk (*language-based approaches*), mezi které řadí především konverzační analýzu (*conversation analysis*), diskurzivní analýzu (*discourse analysis*) a narativní analýzu (*narrative analysis*). V rámci inferenčních metod pak představují Wiseová a Paulusová (2016) čtyři základní typy analýz, které jsou nejčastěji používány pro analýzu online diskuzí. Za jádro inferenčních metod považují autorky obsahovou analýzu (*content analysis*). Ta obvykle spočívá ve čtení a analyzování obsahu jednotlivých příspěvků v diskuzi, v jejich kódování a následné kvantitativní práci s jednotlivými kódy. Tradičně bylo kódování prováděno manuálně, tj. jeden či několik výzkumníků četlo a kódovalo všechny analyzované příspěvky. V současnosti se však již využívají i automatizované či poloautomatizované postupy. Další oblastí je dle uvedených autorek klasická statistická analýza (*statistical analysis*), která často navazuje právě na výsledky obsahové analýzy a pracuje tak nejen např. s počty příspěvků, ale i s počty výskytů jednotlivých kódů apod. Temporální či časová analýza (*temporal analysis*), která je další z uvedených inferenčních metod, se zaměřuje primárně na časové aspekty související s průběhem diskuze v online fórech, jak ostatně napovídá již její název. V neposlední řadě pak autorky uvádí na sítích založenou analýzu (*network-based analysis*), která vesměs odpovídá využití analýzy sociálních sítí (SNA) pro analýzu online diskuzních fór. Právě na využití analýzy sociálních sítí se zaměřuje i tato sonda, a proto se následující kapitoly zaměřují přímo na tento metodologický přístup.

### **5.1.2. Analýza sociálních sítí v kontextu e-learningu a LMS**

Jak bylo naznačeno v dřívějších kapitolách, které se dotýkaly analýzy sociálních sítí (zvláště 2.2.1.3.5. *Analýza sociálních sítí* a 2.3.5.1. *Analytika sociálních sítí*), jde o specifickou sadu metod či lépe specifický metodologický přístup zaměřující se (alespoň v sociálněvědním kontextu) na analýzu lidské interakce a zkoumání vztahů mezi jednotlivci, skupinami lidí či celými komunitami. Ona specifická pramení právě z toho, že hlavním východiskem analýzy sociálních sítí je důraz na vztahy mezi interagujícími jednotkami (Wasserman & Faust, 1994). V průběhu přibližně posledních padesáti let došlo k rozvoji základních

---

<sup>114</sup> Nechávám nyní stranou otázku, zda je označení „inferenční metody“ skutečně vhodné, jelikož často nejde o metody, které by zahrnovaly inferenční statistické postupy. Naopak zde hrají důležitější roli metody vycházející spíše z kontextu exploratorní analýzy dat.

konceptů a principů analýzy sociálních sítí, které jsou v současnosti všeobecně přijímány a široce používány (Stepanyan, Mather, & Dalrymple, 2014). Základními stavebními kameny analýzy sociálních sítí jsou aktéři a vztahy či vazby mezi nimi. Aktéry jsou míněny určité sociální entity (obvykle jedinci, případně větší sociální jednotky jako skupiny lidí), vazbami jsou pak míněny různé formy sociálních vztahů či spojení mezi jednotlivými aktéry. Kombinace obou těchto prvků, tj. jak aktérů, tak vazeb mezi nimi, pak tvoří síť, jejíž strukturu lze zkoumat a analyzovat pomocí analýzy sociálních sítí (Schmid & Šubrt, 2010).

V kontextu e-learningu a výzkumu učení v online prostředí pak můžeme v současnosti nalézt čtyři směry či způsoby využití analýzy sociálních sítí (Haythornthwaite, de Laat, & Schreurs, 2016). První směr, který je zároveň silně akcentován právě v rámci analytiky učení, se zaměřuje na využití analýzy sociálních sítí a zvláště vizualizace sítí jakožto prostředku zpětné vazby a intervence sloužící k podpoře (sociálních) výukových aktivit v online prostředí. V rámci sociální analytiky učení (viz kapitola 2.3.5.) se tak řada výzkumníků a vývojářů věnuje tvorbě specifických nástrojů pro automatickou analýzu a vizualizaci sociálních sítí (viz např. Dawson, Bakharia & Heathcote, 2010; Rabbany, ELAtia, Takaffoli & Zaiane, 2014; Schreurs & De Laat, 2012). Tyto nástroje jsou určeny primárně pro učitele (případně pro studenty), aby jim poskytovaly doplňující informace o průběhu sociálních online aktivit, a tím jim umožňovaly činit informovanější rozhodnutí. Zatím však není dostatek výzkumů, které by se zaměřovaly na efekt či účinek těchto analytických nástrojů a vizualizací (tzn., zda a případně jakým způsobem dostupnost těchto nástrojů ovlivňuje chování studentů či učitelů v online prostředí).

Druhým směrem, který však dle Haythornthwaiteové, de Laata a Schreurse (2016) zatím není výzkumně zastoupen až tak silně, je využívání analýzy sociálních sítí pro zkoumání online (sociálních) výukových aktivit. Zvláštní pozornost je zde věnována především potenciálním prediktorům a proměnným, které souvisí se vznikem a formováním sítí různých typů. Třetí směr výzkumu se pak zaměřuje opět na využití analýzy sociálních sítí pro zkoumání online výukových aktivit, ovšem primárně ve vztahu k úspěšnosti a studijním výsledkům. Obvykle je tak dávána do souvislosti pozice studenta v rámci sítě s jeho studijními výsledky. Konkrétním příkladem může být studie Joksimoviće et al. (2016), kteří analyzovali síť interakcí v diskuzních fórech v rámci kurzu typu MOOC a sledovali vztah mezi pozicí studentů v této síti a jejich (ne)úspěšností s ohledem na dokončení kurzu.

Posledním výzkumným směrem zmiňovaným autory Haythornthwaiteovou, de Laatem a Schreuresem (2016) je pak využití analýzy sociálních sítí pro porozumění učení a učebnímu procesu v online prostředí. Analýza sociálních sítí v této oblasti bývá velmi často kombinována s dalšími metodami (např. zmiňovaná obsahová analýza), aby byl zajištěn

hlubší vhled do zkoumaného fenoménu a mohla být věnována pozornost samotnému učení. V souvislosti s analýzou interakce v online diskuzních fórech tak bývá věnována pozornost nejen tomu, kdo s kým interaguje či na koho reaguje, ale také tomu, čeho se daná interakce týká (tj. o čem se studenti baví) či jakým způsobem spolu studenti komunikují. Jako příklad takového výzkumu kombinujícího analýzu sociálních sítí s obsahovou analýzou lze zmínit studii autorů Heo, Lim a Kim (2010), kteří se zaměřují na online interakci studentských týmů v průběhu projektové výuky.

I přes výše představené směry výzkumu a zmíněné příklady studií je však třeba mít stále na paměti, že v širším kontextu pedagogického výzkumu je využití analýzy sociálních sítí stále relativně nové, a tudíž má řada studií explorační povahu. Dosavadní studie tak obvykle staví spíše na vizualizaci sítí a základních deskriptivních ukazatelích, než že by využívaly pokročilejší statistický aparát, který v současnosti analýza sociálních sítí nabízí (Stepanyan, Mather, & Dalrymple, 2014).

### **5.1.3. Analýza sociálních sítí a interakce v online diskuzních fórech v LMS**

V souvislosti se systémy typu LMS je jedním z nejčastějších způsobů využití analýzy sociálních sítí (SNA) právě využití pro analýzu participace a interakce studentů (a případně učitelů) v online diskuzních fórech (viz např. Brooks, Greer, & Gutwin, 2014; Hernández-García, González-González, Jiménez-Zarco, & Chaparro-Peláez, 2015; Joksimović et al., 2016; Kellogg, Booth, & Oliver, 2014; Rabbany, ELAtia, Takaffoli, & Zaiane, 2014; Wise & Cui, 2018; Zhang, Skryabin, & Song, 2016). I přesto však zůstává v tomto kontextu řada nezodpovězených otázek, a to i těch zcela bazálních. Zvláště pak, pokud zaměříme pozornost specificky na využití LMS v kontextu univerzitního vzdělávání, jako to činí tato disertační práce.

Je třeba si totiž uvědomit, že řada z výše uvedených výzkumů zabývajících se využitím SNA pro analýzu interakce studentů v online diskuzních fórech se zaměřuje na relativně specifické kurzy označované zkratkou MOOC. Ty jsou přitom poměrně výrazně odlišné od online či blended kurzů, které jsou obvyklé v univerzitním prostředí a jež bývají někdy označovány zkratkou SPOC (*small private online course*). Zatímco kurzy typu MOOC jsou otevřené komukoli a obvykle se jich účastní tisíce až desetitisíce studentů, kurzy typu SPOC jsou naopak uzavřené a určené jen pro konkrétní, uzavřenou a zpravidla poměrně malou skupinu studentů (viz Zounek et al., 2016). Dá se přitom očekávat, že tato zásadní odlišnost mezi oběma typy kurzů, se promítá i do způsobu, jakým v nich dochází k interakci mezi studenty v online fórech. Ačkoli tedy již máme určité informace o tom, jak probíhá interakce v kontextu

kurzů typu MOOC, zatím existuje relativně málo studií zabývajících se specificky kurzy typu SPOC. Tudíž zůstává otázkou, nakolik jsou dosavadní výsledky z MOOC platné i v souvislosti s interakcí v diskuzních fórech v rámci SPOC.

Přesto lze zmínit alespoň některé z dosavadních výsledků výzkumů zaměřujících se na interakci v online diskuzních fórech a využívajících analýzu sociálních sítí jako metodologický přístup. Například Brooks, Greer a Gutwin (2014) představují příklady analýz několika různých kurzů a poukazují na užitečnost specifického typu vizualizace sítě, v rámci kterého rozlišují tři základní typy účastníků kurzu: 1) participanti, kteří se aktivně zapojí do diskuze vložím vlastní příspěvek, 2) výše zmiňovaní *lurkers*, jež sice sami nekládají příspěvky, ale čtou příspěvky ostatních a 3) neúčastníci, kteří se do interakce v diskuzním fóru nezapojují ani aktivně (tj. psaním vlastních příspěvků) ani pasivně (tj. čtením příspěvků ostatních). S jinou kategorizací účastníků diskuze přichází Kellogg, Boothová a Oliver (2014), kteří analyzují interakci studentů v kurzu typu MOOC a odlišují čtyři typy účastníků. Reciprocátoři (*reciprocators*) jsou účastníci zapojující se do vzájemných komunikačních výměn, což znamená, že nejen reagují na příspěvek někoho jiného, nýbrž na ně zároveň reaguje autor původního příspěvku. Druhou skupinou jsou síťáři (*networkers*), kteří sice reagují na příspěvky ostatních a zároveň získávají reakce na své příspěvky, ovšem bez vzájemné komunikační výměny. Hlasatelé (*broadcasters*) jsou pak dle autorů studie takoví účastníci diskuze, kteří odstartují nějaké téma či diskuzní vláno, ale v navazující diskusi se již aktivně nezapojují a nepřidávají další příspěvky či reakce. Poslední skupinu pak tvoří tzv. neviditelní (*invisible*), což jsou účastníci, kteří sice přispívají do diskuze, ale nikdy nezískají žádnou reakci na své diskuzní příspěvky.

Wiseová a Cuiová (2018) dále upozorňují na nutnost rozlišovat různé typy interakcí, ke kterým v online diskuzních fórech dochází. Na základě svých předchozích výzkumů, jakož i výsledků výzkumů jiných výzkumníků, dochází k tomu, že přinejmenším v kurzech typu MOOC je vhodné rozlišovat alespoň dva základní typy interakce: na obsah kurzu zaměřené interakce (*content-related interactions*) a jiné interakce, jež se netýkají obsahu kurzu jako takového (*non-content interactions*). Přestože oba typy interakcí mohou mít svou hodnotu („neobsahové“ interakce mohou být důležité např. v rámci vzájemné podpory a motivace), podle zmíněných autorek souvisí s učením spíše na obsah zaměřené interakce. Oba druhy interakcí se rovněž liší tím, jaký komunikační styl v nich převládá a jací studenti se do nich zapojují. V neposlední řadě se pak zdá, že participace v na obsah zaměřených interakcích je lepším prediktorem úspěšnosti v kurzu než celková participace nerozlišující tyto dva zmiňované typy. Na druhou stranu, co se týče vztahu mezi mírami centrality studentů v sítích interakce a jejich úspěšností při dokončování kurzu, dosavadní studie přináší zatím spíše



smíšené výsledky (srov. Hernández-García, González-González, Jiménez-Zarco, & Chaparro-Peláez, 2015; Joksimović et al., 2016).

V souvislosti s menšími kurzy lze zmínit studii, která se zaměřila na srovnání osobních (*egocentric*) sítí studentů s vysokým a nízkým výkonem (viz Ghadirian, Salehi, & Ayub, 2018). Autoři analyzovali data pocházející z blended kurzů a zjistili, že studenti s nejvyšším výkonem (90. percentil a výše) mají výrazně jiné hodnoty měr centrality než studenti s nejnižším výkonem (po 10. percentil). Konkrétně, výkonnější studenti vykazují více centrální pozici v síti než studenti méně výkonní. Tirado-Morueta, Maraver-López a Hernando-Gómez (2017) se rovněž zaměřovali na malý kurz, resp. malé skupiny interagujících studentů, přičemž jejich interakce probíhala v diskuzních fórech v LMS Moodle. Hlavní pozornost však věnovali tomu, jak se liší interakce studentů v závislosti na úkolu, který studenti v průběhu interakce řeší. Výsledky studie přitom naznačují, že při úkolech s volnějším či otevřenějším zadáním a při více komplexních úkolech dochází k vyšší míře zapojení všech členů skupiny. Naopak u úkolů s pevnějším a více strukturovaným zadáním dochází k tomu, že se na vysoké interakci podílí menší množství členů.

Všechny výše uvedené studie však trpí obdobným problémem, který byl zmiňován v rámci sondy A v souvislosti s otázkami zobecnitelnosti a přenositelnosti. I zde totiž citované studie prezentují výsledky analýz realizovaných na velmi malých počtech kurzů (maximálně jednotky). Velmi často jde dokonce jen o jediný kurz, případně několik instancí jednoho kurzu. Stále tak máme jen velmi omezenou představu o tom, jakými různými způsoby může docházet k interakci mezi studenty (a případně učiteli) v online diskuzních fórech v LMS.

## 5.2. Výzkumný problém a otázky sondy B

Výzkumný problém sondy B se zaměřuje na interakci studentů a učitelů v online diskuzních fórech v rámci systémů pro řízení výuky (LMS). Cílem je přitom zjistit, nakolik jsou vůbec diskuzní fóra v online a blended kurzech v LMS využívána a nakolik v nich dochází k interakci mezi studenty a vyučujícími. Dalším cílem je ale také zhodnotit, nakolik je metoda analýzy sociálních sítí (SNA) využitelná pro účely podrobnějšího průzkumu online interakcí v diskuzních fórech a pro účely rozlišování různých forem těchto interakcí mezi studenty a učiteli v LMS. Hlavní výzkumnou otázku (HVO) této sondy lze tak formulovat následovně:

- *HVO: Jak je využitelná metoda analýzy sociálních sítí pro účely zkoumání a rozlišování různých forem interakce studentů a učitelů v online diskuzních fórech v systému pro řízení výuky (LMS)?*

Výše uvedená hlavní výzkumná otázka byla dále rozpracována do následujících čtyř specifických výzkumných otázek (SVO):

- *SVO1: Nakolik jsou v rámci LMS Moodle na FF MU využívány online diskuzní fóra jakožto nástroje pro podporu komunikace a interakce mezi studenty a učiteli?*
- *SVO2: Jaké strukturní formy či typy interakce mezi studenty a učiteli v online diskuzních fórech v LMS lze rozlišit za využití metod SNA?*
- *SVO3: Jaké je četnostní zastoupení jednotlivých forem či typů interakce mezi studenty a učiteli v online diskuzních fórech v LMS?*
- *SVO4: Jak se jednotlivé formy či typy interakce mezi studenty a učiteli v online diskuzních fórech v LMS liší z hlediska vybraných ukazatelů interakce a SNA metrik?*

První specifická výzkumná otázka se zaměřuje na posouzení toho, do jaké míry jsou vůbec online diskuzní fóra využívána jakožto nástroje pro komunikaci a interakci v rámci univerzitních kurzů realizovaných prostřednictvím systému pro řízení výuky. Vzhledem k tomu, že se řada studií zabývá pouze jedním kurzem či velmi malým počtem kurzů, máme jen velmi omezenou představu o tom, nakolik je vůbec interakce a komunikace studentů v online diskuzních fórech součástí výuky realizované v LMS. V souvislosti s LMS Moodle na FF MU sice přinesli určitý vhled Švaříček a Zounek (2008), ovšem jejich studie se nezaměřuje přímo na online diskuzní fóra, a tudíž neposkytuje mnoho informací k této otázce.

Cílem druhé SVO, kterou je zároveň možné považovat za stěžejní otázku této sondy, je kompenzovat výše nastíněný zásadní limit většiny doposud realizovaných studií, jež se zaměřují jen na velmi malé množství kurzů (např. Ghadirian, Salehi, & Ayub, 2018; Joksimović et al., 2016; Kellogg, Booth, & Oliver, 2014; Tirado-Morueta, Maraver-López a Hernando-Gómez, 2017). V rámci této otázky usilují o využití analýzy sociálních sítí pro odhalení různých forem interakce napříč velkým množstvím kurzů různých typů.

Třetí a čtvrtá specifická výzkumná otázka se pak zaměřují na zhodnocení toho, jak častý je výskyt jednotlivých forem interakce v diskuzních fórech a nakolik se jednotlivé formy či typy odlišují z hlediska vybraných kvantitativních ukazatelů participace a interakce účastníků diskuze jakož i ukazatelů popisujících síťový charakter interakční sítě jako celku. Tyto dvě otázky tak především navazují na SVO2 a doplňují další relevantní informace k nalezeným formám interakce.

### 5.3. Metodologie sondy B

Tato studie má především exploratorní povahu, kdy se nesnaží ověřovat předem stanovené hypotézy či předpoklady, nýbrž za využití analýzy sociálních sítí usiluje o odhalení doposud neznámých forem interakce v online diskuzních fórech v LMS. Následující metodologické podkapitoly se zaměřují nejprve na základní představení analýzy sociálních sítí jakožto zvoleného metodologického přístupu. Dále je popsán postup sběru a předzpracování dat a na závěr je představen způsob analýzy dat.

#### 5.3.1. Metodologický přístup – analýza sociálních sítí

Analýze sociálních sítí jakožto specifickému metodologickému přístupu se již v určitém ohledu věnovaly dvě kapitoly této práce. Konkrétně šlo o kapitolu 2.2.1.3.5., která představovala analýzu sociálních sítí jako jednu ze základních analytických metod data miningu ve vzdělávání, a dále kapitolu 2.3.5.1., jež představovala analytiku sociálních sítí jakožto specifickou oblast analytiky učení stavějící primárně na metodologických základech analýzy sociálních sítí. Některé základní informace o analýze sociálních sítí pak nabízí i kapitola 5.1.2. v rámci této sondy. I přes riziko určité repetitivnosti se však domnívám, že je vhodné v této části nastínit alespoň základní pojmy a koncepty související s analýzou sociálních sítí. Představím však skutečně jen naprosté minimum nutné pro porozumění realizované analýze a předkládaným výsledkům (srov. Juhaňák, 2017). Případného čtenáře zajímavějšího se o podrobnější vzhled do analýzy sociálních sítí pak odkáží na některé ze stěžejních publikací věnujících se tomuto metodologickému přístupu (Alhajj & Rokne, 2014; Scott & Carrington, 2011; Wasserman & Faust, 1994), případně na publikace zabývající se analýzou sociálních sítí přímo v kontextu pedagogického výzkumu (Carolan, 2013; Daly, 2010).

Základními prvky při analyzování sociálních sítí jsou tzv. **uzly** (označované také jako *vrcholy* či *body*) a **vazby** (také *hrany* či *spoje*). Uzly reprezentují jednotlivé aktéry, vazby pak reprezentují vztahy mezi danými aktéry. Dohromady pak uzly a vazby mezi nimi tvoří (sociální) **sítě**. S uzly i vazbami mohou být přitom spojeny další charakteristiky (např. typ uzlu, síla vztahu apod.), které pak bývají při vizualizaci sítě zobrazovány pomocí velikosti, barvy, typu apod.

Při popisu sítí se užívá několik klíčových pojmů. V rámci sítě mohou existovat uzly či skupiny uzlů, které nemají žádnou vazbu k ostatním uzlům či skupinám uzlů. V takovém případě hovoříme o tzv. **komponentách**, tj. částech sítě, které jsou zcela odděleny od zbytku sítě. V některých případech má však smysl hovořit o i takových částech sítě, kde vznikají shluky uzlů, které jsou vzájemně silně provázány, kdežto se zbytkem sítě jsou provázány

méně. U takových případů hovoříme o **komunitách**, tj. o skupinách či shlucích uzlů, které sice mají spojení se zbytkem sítě (a tudíž nejde o zcela oddělené komponenty), ale přesto jsou si vzájemněji mnohem blíže než se zbytkem sítě. V neposlední řadě je pak třeba odlišit **orientované a neorientované sítě**. Vazby mezi aktéry v síti mohou být jednosměrné (např. pokud někoho považuji za přítele, tak to ještě nemusí znamenat, že on považuje za přítele mě) nebo obousměrné<sup>115</sup> (jsem-li něčí sourozenec, pak je nutně i on mým sourozencem). Orientovaná síť pak představuje takovou síť, ve které pracujeme s jednosměrnými vazbami, zatímco neorientovaná síť pracuje s obousměrnými vazbami (Schmid & Šubrt, 2010; Scott & Carrington, 2011; Wasserman & Faust, 1994).

Pro účely analýzy (sociálních) sítí je k dispozici řada metrik, které popisují různé aspekty dané sítě a umožňují nám síť kvantitativně popsat a případně srovnat s jinou zkoumanou sítí. Mezi základní SNA metriky týkající se sítě jako celku se řadí především následující:

- **Diametr** či průměr (*diameter*) sítě odkazuje ke vzdálenosti mezi dvěma nejvzdálenějšími uzly v síti. Konkrétně pak diametr udává nejnižší možný počet kroků, pomocí kterého je možné se dostat z libovolného uzlu do jakéhokoli jiného uzlu v síti (tj. vlastně nejkratší možná cesta spojující dva nejvzdálenější uzly v síti). Diametr bývá také využíván jako míra konektivity sítě. Nízké hodnoty diametru totiž značí vysokou propojenost uzlů v síti (tj. mohu se velmi rychle dostat z libovolného uzlu do jiného libovolného uzlu).
- **Hustota** (*density*) sítě je jednoduše poměr počtu existujících vazeb mezi uzly k počtu všech potenciálně možných vazeb mezi uzly (tj. takový případ, kdy by existovala vazba mezi každou dvojicí uzlů).
- **Reciprocita** (*reciprocity*) v rámci orientované sítě vyjadřuje míru existence vzájemných vztahů. Lze ji chápat jako pravděpodobnost toho, že pokud existuje vazba od uzlu A k uzlu B, tak zároveň existuje vazba od uzlu B k uzlu A.
- **Tranzitivita** (*transitivity*) sítě odkazuje k pravděpodobnosti existence vazby mezi uzly, které jsou oba spojeny skrze jiný uzel. Často zmiňovaným příkladem je tendence přátelit se s přáteli svých přátel. Konkrétně lze tranzitivitu ilustrovat následovně: Pokud existuje vazba mezi uzlem A a uzlem B a zároveň existuje vazba mezi uzlem A a uzlem C, nakolik platí, že zároveň existuje vazba mezi uzlem B a uzlem C.

---

<sup>115</sup> Přestože se v češtině v tomto kontextu hovoří o obousměrných vazbách, striktně vzato toto označení není zcela vhodné. Spíše by bylo vhodné hovořit o takových vazbách, které nemají směr (tj. „bezsměrové“).

Při analýze jednotlivých uzlů v síti se pak nejčastěji usiluje o odhalení těch uzlů, které jsou v rámci sítě nějakým způsobem důležité. Tato důležitost (či centralita) přitom může v různých kontextech znamenat různé věci. Mezi tři nejběžněji používané míry centrality přitom patří:

- **Stupeň** (*degree*), resp. vážený stupeň (*weighted degree*), který odpovídá počtu přímých vazeb, který uzel má na jiné uzly v síti. Vážený stupeň přitom bere ohled nejen na počet vazeb, ale i na jejich sílu (tj. vazba nemá pouze binární charakter, nýbrž je vyjádřena určitou mírou síly vazby). V rámci orientovaných sítí se dále rozlišuje počet vazeb směřujících od uzlu (*outdegree*) a počet vazeb směřujících k uzlu (*in-degree*).
- **Blížkost** (*closeness*) měří, kolik kroků je potřeba k dosažení daného uzlu ze všech ostatních uzlů v síti. Vysoká blízkost tak znamená, že je daný uzel dosažitelný z ostatních míst v síti na malé množství kroků.
- **Mezilehlost** (*betweenness*) odpovídá počtu nejkratších cest mezi páry uzlů, které procházejí daným uzlem. U uzlů s vysokou mezilehlostí jde obecně o uzly, které leží na spojnici mezi jinak oddělenými částmi sítě (tj. propojují jinak odlehle komunity). Tyto uzly jsou tudíž centrální v tom smyslu, že mají roli propojovatelů a mohou tak zásadně ovlivňovat tok informací v síti (má-li totiž informace přejít z jedné části sítě do druhé, pak musí obvykle projít právě přes tyto uzly s vysokou mezilehlostí).

### 5.3.2. Postup sběru a předzpracování dat

Tato sonda má za cíl zmapovat formy interakce studentů a učitelů v online diskuzních fórech v LMS Moodle na FF MU. Z toho důvodu bylo přistoupeno k co možná nejúplnějšímu sběru dat a výchozím bodem tak byly všechny kurzy realizované v LMS Moodle na Filozofické fakultě Masarykovy univerzity v rozmezí od podzimního semestru 2012 po jarní semestr 2015. Celkem tedy byla zpracovávána data z kurzů realizovaných v průběhu šesti různých semestrů, přičemž výchozí počet těchto kurzů byl 2986.

Pro všechny kurzy byly získány základní údaje jako: kategorie, ve které je kurz umístěn, datum začátku kurzu, informace o metodě zápisu studentů do kurzu apod. Dále pak byly získány informace týkající se diskuzních fór v kurzech a množství interakce v nich. Konkrétně šlo o údaje jako: počet diskuzních fór v kurzu, počet započatých diskuzí v diskuzních fórech, počet příspěvků v diskuzních fórech, počet studentů zapojených do diskuze ve fórech apod. Na základě těchto informací pak v několika krocích probíhal výběr kurzů pro samotnou analýzu za využití SNA. Šlo o následující kroky:

1. V prvním kroku byly odfiltrovány takové kurzy, které sice v LMS Moodle figuruji jako běžné kurzy, ale ve skutečnosti nejde o kurzy využívané v rámci výuky. Šlo především o různé kurzy využívané administrátory systému pro účely testování či o různé archivní kurzy, které reálně neprobíhaly v žádném z analyzovaných semestrů. Po odfiltrování těchto kurzů zůstávalo k dispozici 2739 kurzů, které je možné považovat za „reálné kurzy“, tj. kurzy ve kterých skutečně probíhala výuka v některém z daných semestrů a které tedy sloužily jako e-learningová podpora některého z vyučovaných předmětů na Filozofické fakultě Masarykovy univerzity.
2. V druhém kroku byly vybrány jen takové kurzy, které obsahovaly alespoň jedno diskuzní fórum, které není fórum typu Novinky. Fórum typu Novinky je totiž v rámci LMS Moodle automaticky vytvářeno při založení nového kurzu. Zároveň jde o specifické fórum, které neslouží k interakci mezi studenty a učiteli, nýbrž pouze k rozesílání oznámení od učitele ke studentům. Pro účely analýz tak kurzy pouze s tímto typem fóra nebyly relevantní, nýbrž byla věnována pozornost jen takovým kurzům, kde vyučující záměrně přidali alespoň jedno další diskuzní fórum standardního typu, v rámci kterého by mohla probíhat interakce mezi studenty a učiteli. Po výběru jen těch kurzů, které obsahovaly alespoň jedno další diskuzní fórum mimo Novinky, zůstalo k dispozici 1488 kurzů.
3. Samotná existence diskuzního fóra v kurzu však ještě neznamená, že skutečně bylo v rámci kurzu využíváno studenty a učiteli. V třetím kroku tak došlo k výběru jen těch kurzů, jež měly v některém ze svých diskuzních fór (mimo fórum typu Novinky) založeno alespoň jedno diskuzní vlákno. Tzn., že byla odstartována alespoň jedna diskuze, a to buď diskuzním příspěvkem vyučujícího či diskuzním příspěvkem studenta. Po tomto výběru zůstalo 861 kurzů.
4. Pro účely aplikace metod SNA však bylo třeba dále odfiltrovat takové kurzy, ve kterých byl rozsah diskuze natolik malý, že by nedávalo smysl analyzovat tyto diskuze pomocí metod SNA. Příkladem může být kurz, ve kterém student v rámci diskuzního fóra položí dotaz vyučujícímu, ten mu odpoví, a následně student poděkuje za odpověď. V takovém kurzu by existovalo diskuzní fórum mimo Novinky a byla by v něm odstartována alespoň jedna diskuze (v technickém slova smyslu). Do této „diskuze“ by se však zapojili pouze dva účastníci kurzu a byly by v ní pouze tři diskuzní příspěvky. V takovém případě by však nemělo příliš smysl vizualizovat „sít“ interakcí mezi studenty a učiteli v kurzu. Proto byla arbitrárně zvolena určitá minimální hranice počtu zapojených účastníků diskuze a počtu vytvořených diskuzních příspěvků. Konkrétně byly vybrány jen takové kurzy, ve

kterých se do interakce v diskuzních fórech zapojilo alespoň 5 účastníků a zároveň bylo v rámci diskuzních fór vytvořeno alespoň 10 diskuzních příspěvků. Po tomto výběru zůstalo **453 kurzů**, které byly dále analyzovány za využití metod SNA.

Poté, co jsem dospěl k finálnímu seznamu kurzů určených pro analýzu, jsem přistoupil k samotné extrakci dat týkajících se interakce uživatelů v online diskuzních fórech. Po získání potřebných dat z databáze Moodle bylo následně nutné data transformovat do takové podoby, aby bylo možné aplikovat postupy analýzy sociálních sítí. Z původně atribučních dat, jak jsou ukládána v databázi Moodle, tak byla vytvořena data relační. A to konkrétně v podobě seznamu vazeb (*edge list*) a seznamu uzlů (*node list*). Data v této podobě je pak možné použít pro tvorbu matice sousednosti a sítě jako takové.

Nutno dodat, že na základě dat z online diskuzních fór lze vytvářet různé typy sociálních sítí resp. sítí interakce. Jak uvádí Wiseová a Cuiová (2018), nejčastěji se přitom v dosavadních výzkumech pracuje se dvěma přístupy k tvorbě sítě. V prvním případě jde o tvorbu sítě na základě vztahu vznikajícího přímou odpovědí jednoho účastníka diskuze na příspěvek jiného účastníka. V tomto případě tudíž existuje vazba v síti jen mezi těmi účastníky, kteří na sebe přímo reagují. V druhém případě pak lze síť vytvářet na základě zapojení se do stejného vlákna v rámci diskuze. V takových sítích jsou pak vazby mezi uzly konstruovány tak, že všichni účastníci zapojující se do diskuze v určitém vláknu mají vazbu na autora původního příspěvku, který celé diskuzní vlákno odstartoval. Pro účely této sondy byl využit první ze zmiňovaných způsobů, tj. vytvoření sítě na základě přímých odpovědí. Tento přístup jednak nabízí přímočarou interpretaci vazeb mezi uzly, jednak jde o způsob tvorby sítě využívaný ve většině studií (např. Hernández-García, González-González, Jiménez-Zarco, & Chaparro-Peláez, 2015; Joksimović et al., 2016; Kellogg, Booth, & Oliver, 2014; Wise & Cui, 2018).

### **5.3.3. Analýza dat**

Co se týče analýzy dat, lze ji v základu popsat pomocí tří hlavních kroků. V prvním kroku byla pro každý ze 453 kurzů vybraných pro účely analýzy vytvořena síť, a tato síť byla následně vizualizována. Při vizualizaci sítí ze všech kurzů byl přitom použit zcela stejný postup:

- Pro stanovení prostorového uspořádání uzlů (tj. rozložení sítě – *layout*) byl využit tzv. silový, silově orientovaný či silově řízený (*force-directed*) algoritmus navržený Fruchtermanem a Reingoldem (1991).

- Barevně byly odlišeny tři typy uzlů, které odpovídaly třem různým rolím účastníků diskuzí v kurzu: učitel<sup>116</sup>, asistent a student. Jde o role, které LMS Moodle umožňuje účastníkům kurzu explicitně přidělit, a tudíž je bylo možné v rámci analýz využít. Role učitel a student jsou součástí běžné instalace LMS Moodle, zatímco role asistent je lokálně vytvořená role v rámci instalace Moodle na FF MU. Z hlediska pravomocí má role asistent obdobná oprávnění jako role učitel, její využití je pak zamýšleno pro případy, kdy má vyučující k dispozici asistenty z řad studentů, kteří mu pomáhají kurz spravovat.
- Velikost uzlů vychází z celkového počtu slov, kterými účastník přispěl do diskuze v rámci všech vložených příspěvků.
- Popisek uzlu (tj. uvedené číslo) odpovídá počtu vložených příspěvků.
- Tloušťka čáry znázorňující vazbu mezi uzly pak vychází z počtu reakcí na příspěvky mezi danými účastníky diskuze ve fórech. Čili čím silnější čára, tím vícekrát reagoval jeden účastník diskuze na druhého.

Vytvořené vizualizace sítí byly přitom vytvářeny především pro účely posouzení strukturního charakteru sítí a jejich následného seskupování do jednotlivých typů a podtypů na základě strukturní podobnosti, což lze považovat za druhý krok analýzy. Typy a podtypy sítí (resp. formy interakce v rámci diskuzních fór) nebyly specifikovány předem (např. na základě literatury), nýbrž vznikaly až při samotném analyzování a posuzování sítí. Každá z vytvořených sítí pak mohla být zařazena pouze do jednoho typu resp. podtypu.

Jakmile byla vytvořena typologie sítí a všechny analyzované sítě byly přiřazeny k některému z typů, přistoupil jsem k poslednímu kroku analýzy, kterým byl výpočet jednotlivých metrik interakce v rámci diskuzních fór. Zde přitom byly rozlišovány základní metriky a SNA metriky. Mezi základní metriky patřily: celkový počet účastníků diskuze, celkový počet příspěvků v diskuzi, počet příspěvků na jednoho účastníka, počet slov na jednoho účastníka, celkový počet příloh k diskuzním příspěvkům a počet příloh na jednoho účastníka. Všechny uvedené metriky přitom byly vypočítány jednak obecně za všechny účastníky diskuze dohromady, jednak zvlášť pro každou z analyzovaných rolí (tj. učitel, asistent, student). V rámci SNA metrik pak byly při analýze využity následující: diametr sítě, hustota sítě, reciprocita sítě, tranzitivita sítě, průměrný počet vazeb směřujících od účastníka (*outdegree*), průměrný počet vazeb směřujících k účastníkovi (*in-degree*), počet reakcí

---

<sup>116</sup> V rámci LMS Moodle je vyučujícím standardně přidělována jedna ze dvou dostupných učitelských rolí: „učitel“ a „needitující učitel“. Přestože se obě role poměrně zásadně liší z hlediska oprávnění, jsou v rámci analýz obě chápány jako učitelské. Tudíž uzel, který má v kurzu jednu či druhou roli, je barevně označen jako učitel.



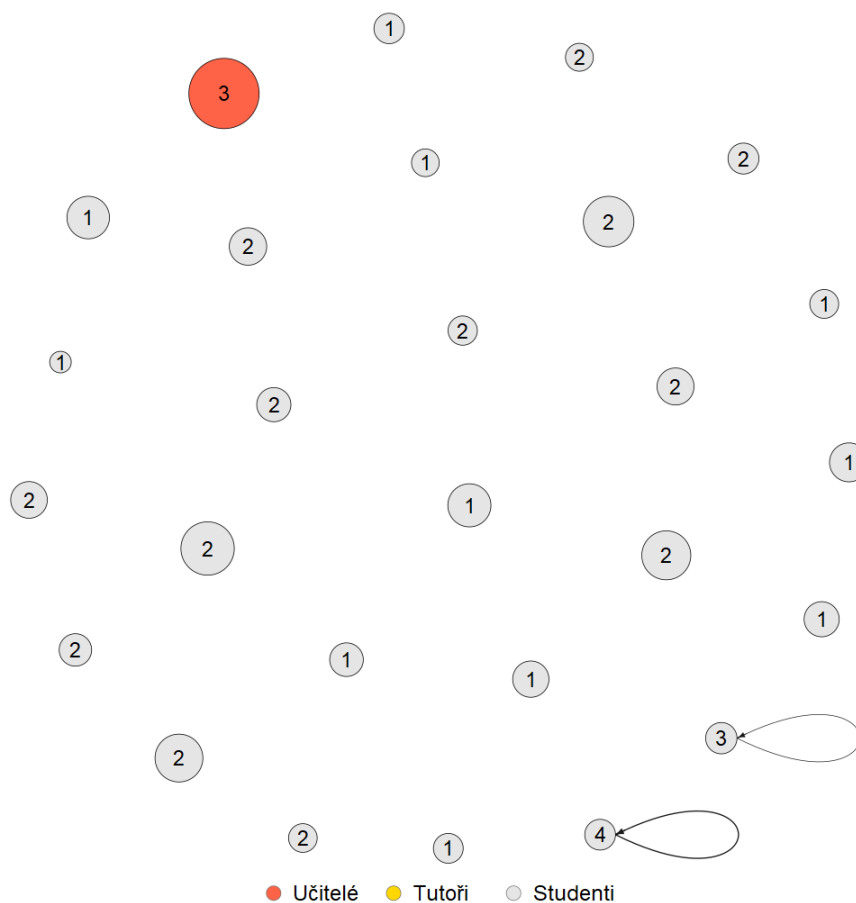
směřujících od účastníka (tj. vlastně vážený *outdegree*) a počet reakcí směřujících k účastníkovi (vážený *in-degree*). V případě metrik týkajících se konkrétních uzlů (stupeň a vážený stupeň) pak byly opět vypočítávány jednak souhrnné metriky pro všechny účastníky dohromady, jednak zvlášť pro každou z analyzovaných rolí.

Analýzy byly realizovány primárně za využití analytického programu *R* (R Core Team, 2018), resp. prostředí *RStudio* (RStudio Team, 2016), a to především pomocí specializovaného balíčku *igraph* (Csárdi & Nepusz, 2006), který poskytuje nástroje pro analýzu a vizualizaci sociálních sítí.

## 5.4. Výsledky sondy B

Na základě vizualizace sítí interakcí mezi studenty a učiteli v online diskuzních fórech v jednotlivých kurzech a následného průzkumu strukturních parametrů jednotlivých sítí byly v analyzovaných kurzech identifikovány čtyři základní formy či typy interakcí (dále označované typ A až typ D), přičemž u některých z těchto základních typů bylo možné navíc identifikovat několik specifických podtypů (dále označované např. B<sub>1</sub>, B<sub>2</sub> atd.). V následujících odstavcích proto budou nejprve postupně popsány nalezené typy a podtypy interakcí mezi studenty a učiteli v online diskuzních fórech v LMS.

První nalezený typ, **typ A**, odpovídá situaci, kdy jsou sice v rámci kurzu v LMS využívána diskuzní fóra, do kterých studenti a případně i učitelé přispívají, ovšem jsou využívána takovým způsobem, že **nedochází k žádné interakci**. A to ani mezi učitelem a jednotlivými studenty, ani mezi studenty navzájem. Příklad vizualizace takové „interakce“ nabízí obrázek 20, ze kterého je patrné, že daná „sít“ vlastně ani není sítí v pravém slova smyslu, protože obsahuje pouze jednotlivé aktéry (studenty a učitele), ale nikoli vazby mezi nimi. Věcně to přitom znamená, že studenti (a případně učitelé) sice do fóra vkládají diskuzní příspěvky, ale vkládají je takovým způsobem, že na sebe vzájemně nereagují. Technicky to pak v LMS Moodle znamená, že každý takový diskuzní příspěvek vlastně zakládá novou diskuzi (či diskuzní vlákno), ovšem v dané diskuzi již další diskuzní příspěvky nepřibývají. Jedinou výjimkou jsou situace, kdy vyučující či student reagují na svůj vlastní dřívější příspěvek, což je na obrázku znázorněno pomocí vazby směřující ke stejnému aktérovi, od kterého vychází (tzv. *self-loop*).




Obrázek 20: Příklad interakce typu A – žádná interakce.

Vysvětlení takového způsobu interakce resp. „neinterakce“ v diskuzních fórech zřejmě spočívá v tom, že diskuzní fóra v těchto kurzech nejsou ve skutečnosti využívána pro účely diskuze a komunikace, nýbrž v kurzu slouží k jiným účelům. V případě příspěvků vyučujících může jít o způsob využívání odpovídající fóru typu Novinky, které bylo zmíněno výše. Tzn., že vyučující využívá fórum jako jednosměrný komunikační kanál, kde zveřejňuje aktuální informace či oznámení pro studenty. V případě příspěvků od studentů pak může jít o situace, kdy diskuzní fórum slouží pouze jako místo pro odevzdávání úkolů (tj. je vlastně využíváno jiným způsobem, než pro který je primárně určeno). U aktivity takového typu se pak neočekává interakce mezi studenty, nýbrž každý student pouze založí své vlastní „diskuzní“ vlákno, v rámci kterého odevzdá požadovaný úkol.

Druhým základním typem je **typ B**, který je charakteristický spíše **nízkou úrovní interakce** mezi studenty a učiteli. V rámci tohoto základního typu lze rozlišit tři různé podtypy (B1, B2 a B3), přičemž první dva jsou obecnějšího charakteru (jsou více rozšířené),

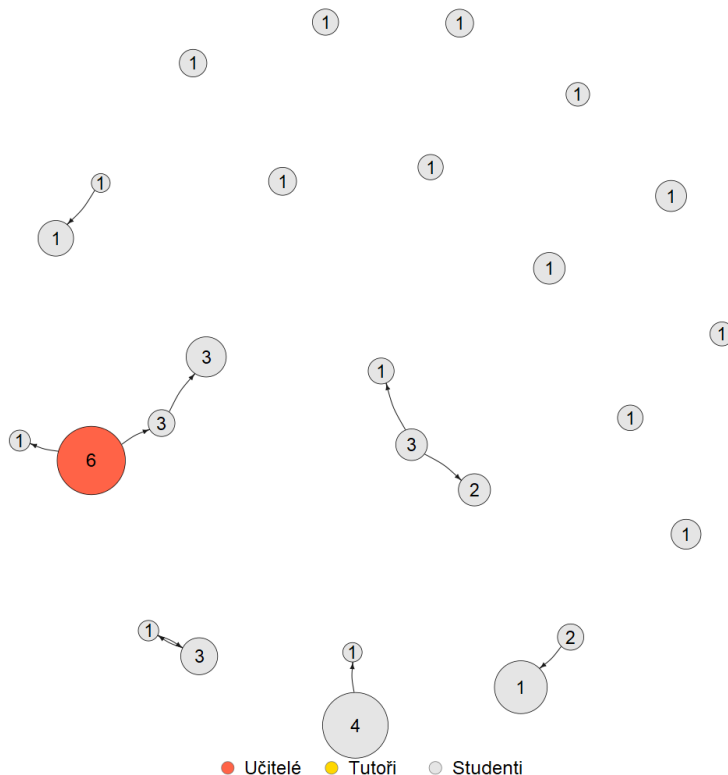
zatímco poslední podtyp je poměrně specifický a vyskytoval se pouze ve dvou z analyzovaných kurzů.

**Podtyp B1** se vyznačuje tím, že se do diskuze zapojuje pouze **malé množství participantů** a zároveň mezi účastníky dochází pouze k malému množství interakcí. Příklad kurzu s takovou formou interakce ukazuje obrázek 21. Do této kategorie přitom mohou spadat jednak kurzy, kterých se účastní velmi malé množství studentů (např. kolem pěti), a tudíž se jich do diskuze ve fórech ani více zapojit nemůže, jednak sem spadají kurzy (což je častější případ), kterých se sice účastní větší množství studentů, ale jen málo z nich se zapojí do diskuze. Jedním z možných vysvětlení je to, že využívání diskuzních fór v těchto kurzech je založeno na dobrovolné bázi a studenti tedy fórum využít nemusí. Příkladem může být situace, kdy vyučující v kurzu založí fórum pro řešení studentských dotazů či nejasností. Jiným příkladem mohou být dobrovolná diskuzní fóra pro spíše neformální diskuzi. V takových případech se do diskuze ve fóru mohou zapojit skutečně jen ti studenti, kteří mají nějaký dotaz nebo zájem, a tudíž celkové množství participantů může zůstat poměrně malé. V každém případě se však zdá, že v kurzech tohoto typu nehraje diskuzní fórum dominantní roli, případně není využíváno v rámci samotných výukových aktivit.




Obrázek 21: Příklad interakce typu B1 – málo participantů.

Druhým podtypem základního typu B je **podtyp B2**, pro který je charakteristické zapojení **většího množství participantů**, mezi nimiž však dochází jen k poměrně **malé úrovni interakce**. Výsledná síť interakce studentů a učitelů kurzu obvykle sestává z řady aktérů bez jakýchkoli vazeb a z několika samostatných komponent sítě, ve kterých existují vazby pouze mezi několika málo aktéry (viz obrázek 22). Tento podtyp má přitom z hlediska věcného významu zřejmě blíže k typu A než k podtypu B1. Oproti podtypu B1 lze totiž předpokládat, že diskuzní fórum v kurzech tohoto typu je využíváno v rámci určité výukové aktivity. Ať již jde o odevzdávání nějakého úkolu, jako tomu bylo u typu A, anebo o jiný druh výukové aktivity předpokládající zapojení většího množství (případně všech) studentů kurzu. Oproti typu A však v tomto případě již vyučující reaguje alespoň na některé příspěvky studentů (přestože většina příspěvků stále zůstává bez jakékoli zpětné vazby) a stejně tak se vyskytují dílčí vzájemné reakce studentů na vkládané příspěvky. Diskuzní fórum v kurzech tohoto typu tak zřejmě hraje určitou výukovou roli, ovšem tato výuková aktivita není výrazně řízena, resp. zapojení vyučujícího do této aktivity je spíše volné a nesystematické (resp. může být systematické v tom smyslu, že se vyučující například vyjadřuje pouze k takovým diskuzním příspěvkům, které jsou nějakým způsobem problematické, nebo potřebují komentář či doplnění učitele).



Obrázek 22: Příklad interakce typu B2 – hodně participantů, málo interakce.


Posledním podtypem základního typu B je značně specifický **podtyp B3**. Ten má podobu **interakce ve tvaru „hada“**, tj. dlouhé linie na sebe navazujících účastníků diskuze (viz obrázek 23). Síťová struktura tohoto typu je velmi neobvyklá a neočekávatelná. Zároveň nenabízí přímočarou interpretaci ve smyslu toho, jaký způsob využití diskuzního fóra by mohl vést ke struktuře interakcí takového typu. V každém případě lze ale předpokládat, že půjde o využití v rámci nějaké poměrně specifické a jasně organizované výukové aktivity. Zároveň však (přínejmenším v tomto konkrétním případě) nejde o aktivitu, která by byla založena na obousměrné interakci. Jak je patrné ze směru šipek, ve většině případů na obrázku mají pouze jeden směr. Čili student A sice navazuje na příspěvek studenta B, ovšem ten nereaguje zpětně na studenta A, nýbrž naopak navazuje zase na jiného studenta.



Obrázek 23: Příklad interakce typu B3 – interakce typu „had“.

Třetím základním typem, který byl v analyzovaných kurzech identifikován, je **typ C**, který spočívá v **interakci ve tvaru hvězdy**, přičemž v centru interakce figuruje učitel. Při využití anglického jazyka by se nabízelo označení *teacher-centered interaction*, což by bylo možné (ačkoli s poněkud posunutým významem) přeložit jako interakce orientovaná na učitele.


Orientace ve tvaru hvězdy znamená, že se v kurzu vyskytuje interakce primárně mezi učitelem a studenty (ať již směrem od učitele ke studentům, anebo naopak) a naopak spíše jen ojediněle se objevuje interakce mezi studenty navzájem. I v tomto typu interakce přitom bylo možné rozlišit několik různých podtypů. Např. v prvním **podtypu C1** (viz obrázek 24) se jedná o **interakci od studentů k učiteli**. Jde tedy o jednosměrnou interakci, kdy studenti vkládají své příspěvky jakožto reakce na nějaký příspěvek či příspěvky vyučujícího, ale příspěvky vyučujícího nejsou reakcemi na příspěvky studentů. Zde se nabízí vysvětlení, že jde o využití, ve kterém vyučující např. zadává úkol či otázku, na kterou následně studenti odpovídají, ovšem součástí této aktivity již není zpětná vazba učitele na konkrétní řešení či odpovědi studentů.



Obrázek 24: Příklad interakce typu C1 – od studentů k učiteli.

Druhý podtyp základního typu C je do značné míry opačný k prvnímu podtypu. V **podtypu C2** (viz obrázek 25) jde opět o jednosměrnou interakci, tentokrát je to však **interakce od učitele ke studentům**. Oproti předchozímu podtypu je to tedy učitel, který vkládá své diskuzní příspěvky jakožto reakce na příspěvky studentů. Jako vysvětlení takového způsobu interakce se nabízí to, že podobně jako v případě typu A nejsou diskuzní fóra v těchto


kurzech ve skutečnosti využívána pro účely diskuze, ale slouží spíše jako místo pro odevzdávání úkolů. Odevzdávání úkolů je pak (obdobně jako u typu A) organizováno tak, že každý student zakládá vlastní „diskuzní“ vlákno. Oproti typu A je pak rozdíl v tom, že vyučující poskytuje zpětnou vazbu na odevzdané úkoly studentů. Žádná další komunikace se však mezi studentem a učitelem nerozvíjí, čímž se zároveň podtyp C2 liší od **podtypu C3**, který stále spočívá v interakci ve tvaru hvězdy, ovšem již dochází k **obousměrné interakci**, tj. jak od studentů k učiteli, tak i od učitele ke studentům (viz obrázek 26).



Obrázek 25: Příklad interakce typu C2 – od učitele ke studentům.

Věcně může jít v případě podtypu C3 o situaci, kdy je diskuzní fórum opět využíváno primárně pro účely odevzdávání úkolů, oproti podtypu C2 však dochází nejen k poskytnutí zpětné vazby učitelem, nýbrž i k další navazující komunikaci mezi studentem a učitelem nad odevzdaným úkolem. Případně může jít o výukovou aktivitu, která spočívá v odevzdávání další verze úkolu na základě zpětné vazby učitele, či obecně aktivitu zahrnující více fází odevzdávání prací studenty a poskytování zpětné vazby učitelem. Podtyp C3 však může znamenat také to, že vyučující v jednom kurzu kombinuje aktivity v podobě podtypu C1 a aktivity v podobě podtypu C2, což se při zkombinování dat o interakci z celého kurzu do jedné sítě projeví jako obousměrná komunikace. V takovém případě by tedy ve skutečnosti

nešlo o obousměrnou komunikaci, nýbrž o dvě výukové aktivity s jednosměrnou komunikací různého typu (tj. v jedné aktivitě by šlo o komunikaci od učitele ke studentům, zatímco v druhé aktivitě naopak o komunikaci od studentů k učiteli).




Obrázek 26: Příklad interakce typu C3 – interakce oběma směry.

Posledním podtypem základního typu C je **podtyp C4**, v rámci kterého dochází k tomu, že v na učitele orientované interakci figurují **dva různé učitelé**. Tzn., že interakce v kurzu má stále podobu hvězdy, ve středu hvězdy však není pouze jeden vyučující, nýbrž dva (viz obrázek 27).

Věcně může jít v případě typu C4 o podobnou situaci jako u podtypu C3 jen s tím rozdílem, že místo jednoho učitele se do komunikace v diskuzních fórech zapojují učitelé dva. Tzn., že může jít jak o jednu výukovou aktivitu s obousměrnou komunikací, tak i o více výukových aktivit, ve kterých probíhá pouze jednosměrná komunikace. Pokud bychom jako konkrétní příklad vzali uvedený obrázek, pak se nabízí dvě možnosti. V prvním případě může jít o aktivitu, v rámci které mají oba učitelé rozdělené role. Zatímco jeden z vyučujících dává




zadání a zajišťuje sběr odpovědí od studentů (resp. studenti vkládají své odpovědi jakožto reakce na jeho příspěvek, což naznačují šipky směřující k učiteli), tak druhý vyučující naopak zajišťuje poskytování zpětné vazby na odevzdané příspěvky studentů (což značí šipky směřující od učitele). Druhou možností je však to, že jde o dvě různé aktivity využívající diskuzní fórum v rámci jednoho kurzu, přičemž každou z aktivit řeší jiný vyučující. Jeden vyučující pak vlastně využívá interakci v podobě podtypu C1, zatímco druhý využívá interakci v podobě C2. Při kombinaci dat za celý kurz se pak interakce projevuje v podobě sítě uvedené na obrázku 27. Do podtypu C4 však spadají různé situace. V některých kurzech mají učitelé „odlišnou roli“ jako v případě uvedeného obrázku, v jiných kurzech však mají oba učitelé stejnou roli ve smyslu zapojení do stejného způsobu interakce, a to jak jednosměrného (tj. oba učitelé zapojení do jednosměrné interakce stejného typu), tak i obousměrného (tj. oba učitelé zapojení do obousměrné komunikace).



Obrázek 27: Příklad interakce typu C4 – dva učitelé ve středu.

Posledním základním typem je interakce **typu D**, která se vyznačuje **intenzivní interakcí**, a to jak mezi učiteli a studenty, tak především mezi studenty navzájem. V podstatě teprve v kurzech s interakcí tohoto typu dochází k využití online diskuzních fór v souladu s jejich primárním účelem, tj. zajištění obousměrné komunikace napříč různými účastníky kurzů. I v rámci typu D lze přitom rozlišit několik specifických a vzájemně odlišných podtypů.

Prvním podtypem základního typu D je **podtyp D1**, ve kterém dochází k interakci, jež lze označit jako **interakci ve velké skupině se silným středem**. Jde o interakci, do které se zapojuje relativně velké množství účastníků kurzu (desítky), přičemž různí účastníci se zapojují různou měrou. A to jak co se týče počtu vložených diskuzních příspěvků, tak co se týče počtu reakcí na ostatní účastníky kurzů. Výsledná vizualizace v podobě sítě pak vypadá tak, že na okrajích sítě zůstávají účastníci kurzu, kteří do diskuzních fór přispěli spíše menším množstvím příspěvků, zatímco čím více se blížíme středu sítě, tím spíše se setkáváme s účastníky, kteří vložili spíše větší množství příspěvků do diskuzních fór v kurzu. Obvykle se pak ve středu sítě vyskytuje učitel nebo několik učitelů či tutorů (viz obrázek 28).



Obrázek 28: Příklad interakce typu D1 – interakce ve velké skupině se silným středem.

Takový charakter resp. struktura sítě se přitom nejvíce blíží „přirozené“ komunikaci v online diskuzních fórech, tzn. v takových diskuzních fórech, které nemají vzdělávací resp. výukový charakter a kde diskuze není explicitně řízena. V případě přirozené neřízené diskuze totiž obvykle dochází právě k tomu, že se různí účastníci zapojují v různé míře, a že mezi některými účastníky či podskupinami diskutujícími se rozvíjí diskuze více než mezi jinými. K tvorbě nových vazeb (tj. v tomto kontextu tedy přidávání nových příspěvků do diskuze v podobě reakcí na již existující diskuzní příspěvky) zároveň v těchto „přirozených podmínkách“ dochází tzv. preferenčním způsobem<sup>117</sup>, což znamená, že nové vazby vznikají spíše v těch částech sítě, kde už existuje dostatečně velké množství příspěvků a vazeb předchozích<sup>118</sup>.

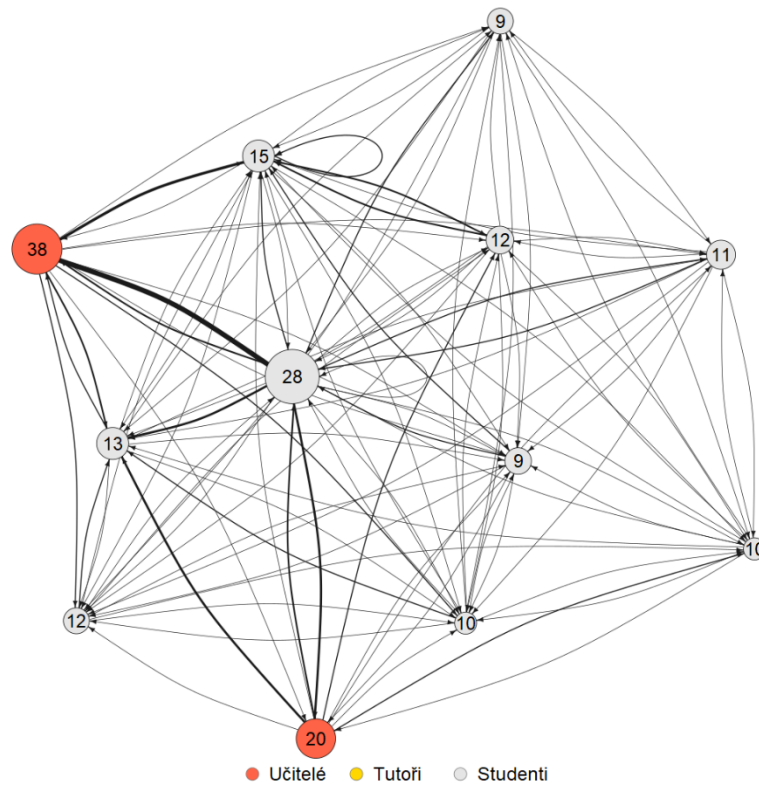
Vyučující v takovém online diskuzním fóru buď explicitně usiluje o to, aby diskuze probíhaly v jistém ohledu „přirozeným“ způsobem, anebo se mu daří zadáním výukové aktivity či způsobem jejího vedení navodit takovou atmosféru, ve které se interakce může rozvíjet „přirozeně“. Z velké míry zapojení vyučujícího (či dokonce většího množství vyučujících jako na obrázku níže) lze však zároveň usuzovat na záměr vyučujícího interakci mezi studenty aktivně podporovat a usilovat o její rozvoj. Na základě poměrně velké míry zapojení některých studentů (např. až 27 či 23 diskuzních příspěvků na obrázku 28) je pak možné předpokládat, že interakce v diskuzních fórech buď vůbec nemá povinný charakter (tj. není to tak, že každý student musí např. vložit určité množství diskuzních příspěvků), anebo se vyučujícím v kurzech tohoto typu daří do značné míry rozvíjet diskuzi i nad rámec minimálního povinného zapojení.

Dalším podtypem základního typu D je **podtyp D2** charakteristický **intenzivní interakcí v malé skupině**. Tvar sítě interakce v tomto typu kurzů pak naznačuje, že jde o kurzy, ve kterých dochází k obousměrné komunikaci vesměs mezi všemi účastníky kurzu navzájem. Vybereme-li jakéhokoli studenta na obrázku 29, pak můžeme najít alespoň jednu vazbu téměř na každého z ostatních účastníků kurzu.

---

<sup>117</sup> Barabási (2005) v této souvislosti hovoří o principu či zákonu preferenčního připojování a takové sítě označuje jako bezškálové.

<sup>118</sup> Věcně řečeno, nový účastník zapojující se do diskuze se spíše zapojí tam, kde již existuje živá diskuze, spíše než by reagoval na nějaký „okrajový“ příspěvek, na který neexistují žádné reakce.




Obrázek 29: Příklad interakce typu D2 – intenzivní interakce v malé skupině.

Z věcného hlediska lze předpokládat, že v případě typu D2 půjde spíše o kurzy seminárního charakteru, ve kterých hraje interakce v online diskuzních fórech důležitou roli. Zároveň lze předpokládat, že charakter interakce v podobě „všichni komunikují se všemi“ není dán pouze tím, že jde o relativně malou skupinu. Podíváme-li se totiž podrobněji na obrázek 29, vidíme, že někteří studenti vložili „pouze“ devět či deset diskuzních příspěvků, což s ohledem na celkový počet účastníků diskuze znamená, že na každého reagovali pouze jednou. Z toho lze usoudit, že nejde o „přirozenou“ diskuzi s preferenčními vazbami, nýbrž je zřejmě součástí zadání diskuzní aktivity explicitní požadavek na to, aby studenti reagovali na všechny či co možná největší počet ostatních studentů. Přesnější představu o charakteru diskuzních aktivit tvořících tento podtyp by poskytla až podrobnější analýza zaměřující se např. na postupnost vzniku sítě. Jako jeden z možných příkladů si lze ale představit aktivitu, v rámci které každý týden některý ze studentů iniciuje diskuzi vlastním příspěvkem, na který pak mají za úkol ostatní studenti nějakým způsobem reagovat. V kurzu jako celku pak tento typ aktivity vede k takové struktuře interakce, v níž dochází k obousměrné komunikaci všech se všemi.

Ve třetím podtypu označeném jako **podtyp D3** dochází k **rovnoměrnému zapojení ve velké skupině**. Podobně jako v případě podtypu D1 a na rozdíl od podtypu D2 jde o kurzy se spíše větším množstvím studentů, kteří se zapojují do diskuzí v online fórech.

2




Obrázek 30: Příklad interakce typu D3 – rovnoměrná interakce ve velké skupině.

Oproti podtypu D1 však v těchto kurzech nedochází k interakci, která by měla z hlediska struktury „přirozený“ charakter, nebo se mu alespoň do určité míry blížila. Naopak síť podtypu D3 vykazuje velmi nepřirozenou strukturu, kdy je zapojení jednotlivých aktérů sítě poměrně rovnoměrné<sup>119</sup>. A to jednak s ohledem na počet vložených příspěvků do diskuze,

<sup>119</sup> Barabási (2005) v tomto kontextu hovoří o náhodných sítích. Oproti bezškálovým sítím, které se řídí principem preferenčního připojování, se náhodné sítě řídí principem náhodné připojování. Věcně to pak v našem kontextu znamená, že noví účastníci diskuze se nezapojují primárně tam, kde již existuje nějaká diskuze, nýbrž se stejnou pravděpodobností zareagují na příspěvek, který je součástí živé diskuze, stejně jako na příspěvek, který

jednak s ohledem na množství vazeb. Většina studentů na obrázku 30 přispěla do diskuze čtyřikrát, přičemž reagovala na dva různé studenty kurzu. Rovněž rozložení vazeb je spíše rovnoměrné a nevznikají tak dílčí shluky či jeden silný střed jako v případě podtypu D1. Z věcného hlediska lze tedy předpokládat, že diskuzní aktivita v kurzech tohoto podtypu je explicitně řízena a zároveň se příliš nerozvíjí nad rámec povinného zadání (oproti podtypu D1). Např. z obrázku níže lze usoudit, že úkolem studentů bylo vložit čtyři diskuzní příspěvky a zároveň alespoň dvakrát reagovat na příspěvky ostatních studentů.



Obrázek 31: Příklad interakce typu D4 – skupinová interakce.

zatím nemá žádné reakce. To pak vede ke struktuře sítě, ve které mají všichni aktéři přibližně stejné množství příspěvků a stejné množství vazeb. V sítích tohoto typu tak nevznikají shluky či centra s výrazně silnější interakcí mezi jednotlivými aktéry oproti zbývajícím částem sítě.

Posledním podtypem, ve kterém dochází k intenzivní interakci, je **podtyp D4**. Přestože tento podtyp není příliš častý, je zajímavý především v tom ohledu, že v něm dochází ke specifickému využití diskuzních fór pro účely **skupinové interakce**. Jak je patrné z obrázku 31, v sítích tohoto typu dochází k tomu, že probíhá velmi intenzivní interakce v rámci několika skupin studentů, ale zároveň nedochází k téměř žádné interakci napříč těmito skupinami. Do značné míry jediným aktérem spojujícím jednotlivé skupiny je tak vyučující, který se zapojuje do komunikace v různých skupinách.

Konkrétně na obrázku 31 vidíme čtyři různé skupiny diskutujících studentů a dva různé učitele, kteří se do komunikace v diskuzních fórech zapojují. Zároveň je patrné, že zatímco první vyučující se zapojuje do diskuze pouze ve dvou ze čtyř skupin, druhý z vyučujících má vazby na všechny čtyři skupiny studentů (přestože i zde jsou dominantní dvě ze čtyř existujících skupin). Z věcného hlediska je na základě struktury sítě podtypu D4 zřejmé, že diskuzní fóra v kurzech tohoto typu jsou využívána pro skupinově orientovanou výukovou aktivitu. Zároveň se však nezdá, že by vyučující těchto kurzů využívali dostupných možností systému Moodle pro rozdělování uživatelů do skupin<sup>120</sup>.

Tímto jsou popsány všechny základní typy a podtypy sítí interakce v online diskuzních fórech nalezené v analyzovaných datech. Tabulka níže (viz tabulka 12) pak nabízí přehled týkající se četnosti výskytu jednotlivých typů a podtypů nalezených sítí. Z dat v tabulce je patrné, že na úrovni čtyř základních typů je výskyt jednotlivých typů přibližně stejně častý. Každý ze základních typů se tak vyskytuje přibližně ve čtvrtině případů. V rámci typu B (malá interakce) je přibližně stejně velké zastoupení podtypu B1 (málo participantů) a podtypu B2 (hodně participantů, málo interakce), zatímco poslední podtyp B3 (interakce typu „had“) je naopak velmi ojedinělý. V rámci typu C (interakce ve tvaru hvězdy) je dominantní varianta interakce od studentů k učitelům (podtyp C1), která tvoří více jak 40 % případů tohoto typu. Zbývající tři podtypy se pak pohybují kolem 20 % či mírně méně. V posledním základním typu D (intenzivní interakce) pak jednoznačně převažuje podtyp D1 (interakce ve velké skupině se silným středem), která se objevuje ve více jak 70 % případů, které spadají pod typ D. Na druhém místě najdeme intenzivní interakci v malé skupině (podtyp D2) vyskytující se ve 14 % případů. Naopak skupinová interakce (podtyp D4) se vyskytuje v méně jak 4 % případů.

---

<sup>120</sup> To je patrné z toho, že v síti přeci jen existuje i několik málo vazeb napříč skupinami, což by nebylo možné, kdyby v kurzu byl využit tzv. skupinový režim.

Tabulka 12: Četnosti výskytu jednotlivých typů interakce mezi studenty a učiteli v online diskuzních fórech v rámci kurzů v LMS.

	počet	%
<b>Typ A – žádná interakce</b>	<b>106</b>	<b>23,4</b>
<b>Typ B – malá interakce</b>	<b>114</b>	<b>25,2</b>
- z toho podtyp B1 – málo participantů	53	46,5
- z toho podtyp B2 – hodně participantů, málo interakce	59	51,8
- z toho podtyp B3 – interakce typu „had“	2	1,8
<b>Typ C – interakce ve tvaru hvězdy</b>	<b>126</b>	<b>27,8</b>
- z toho podtyp C1 – od studentů k učiteli	55	43,7
- z toho podtyp C2 – od učitele ke studentům	23	18,2
- z toho podtyp C3 – interakce oběma směry	26	20,6
- z toho podtyp C4 – dva učitelé ve středu	22	17,5
<b>Typ D – intenzivní interakce</b>	<b>107</b>	<b>23,6</b>
- z toho podtyp D1 – interakce ve velké skupině se silným středem	79	73,8
- z toho podtyp D2 – intenzivní interakce v malé skupině	15	14
- z toho podtyp D3 – rovnoměrné zapojení ve velké skupině	9	8,4
- z toho podtyp D4 – skupinová interakce	4	3,7
<b>Celkem</b>	<b>453</b>	<b>100</b>

Následující tabulky (tj. tabulky 13 až 17) nabízí informaci o tom, jak se výše identifikované typy a podtypy interakce v online diskuzních fórech vzájemně liší, a to jednak co se týče základních indikátorů interakce jako je počet vložených diskuzních příspěvků apod., jednak co se týče vybraných SNA metrik popisujících strukturní stránku analyzovaných sítí.

Tabulka 13 prezentuje odlišnosti v jednotlivých ukazatelích interakce mezi základními čtyřmi typy. Vidíme, že obecné typy se příliš neliší z hlediska počtu zapojených účastníků. Mírně méně je jich v průměru (medián) v rámci typu B (9), zatímco naopak mírně více v typu D (16). To ostatně souhlasí s výše popsáním zastoupením jednotlivých podtypů, kdy v rámci typu B tvoří téměř polovinu malé sítě, zatímco typ D tvoří téměř ze tří čtvrtin relativně velké skupiny účastníků diskuze. Zřejmý trend je naopak patrný v počtu příspěvků vložených do diskuze, kdy počet příspěvků roste s tím, jak se pohybujeme od typu A po typ D. A to ať již se díváme na celkový počet příspěvků v diskuzi, počet příspěvků od učitelů, či průměrný počet příspěvků na jednoho studenta. Obdobná tendence je zřejmá, i co se týče délky příspěvků (měřeno počtem slov). Zajímavou informací je pak zjištění, že v rámci typu D přispívají učitelé



do diskuze v průměru menším počtem slov než studenti (713 versus 762), a to i přesto, že v průměru vkládají více příspěvků (13 versus 8). To naznačuje, že se v tomto typu interakce studenti zapojují do diskuze se spíše delšími příspěvky v porovnání s vyučujícími. Častější výskyt příloh k diskuzním příspěvkům v typu A pak podporuje výše zmíněný předpoklad, že jsou u tohoto typu diskuzní fóra častěji využívána pro účely odevzdávání úkolů místo pro účely diskuze.

*Tabulka 13: Základní ukazatele interakce v diskuzních fórech dle jednotlivých typů interakce. Vzhledem k výraznému zešíkmení rozdělení u většiny proměnných je jakožto průměrný počet reportován medián místo aritmetického průměru. V závorce je pak vždy uvedeno mezikvartilové rozpětí jakožto míra rozptýlenosti.*

	<b>Typ A</b>	<b>Typ B</b>	<b>Typ C</b>	<b>Typ D</b>
<i>Průměrný počet účastníků diskuze</i>	14 (10)	9 (12)	12 (10)	16 (15)
<i>Průměrný počet příspěvků v diskuzi</i>	23 (24,8)	25 (27)	41,5 (52,5)	170 (202,5)
<i>Průměrný počet příspěvků od učitelů</i>	1 (2)	6 (9)	11 (17,8)	13 (41,5)
<i>Průměrný počet příspěvků od studentů</i>	22 (26)	17,5 (25)	25,5 (37,2)	129 (173,5)
<i>Průměrný počet příspěvků na studenta</i>	1,7 (1,1)	1,9 (1,4)	2,2 (1,7)	8,2 (7,4)
<i>Průměrný počet slov na účastníka</i>	66,2 (158,3)	164,5 (239,4)	192 (257,7)	891,3 (1253,9)
<i>Průměrný počet slov na učitele</i>	80,5 (145,2)	269 (367,6)	479,5 (984,1)	713 (2140,6)
<i>Průměrný počet slov na studenta</i>	53,6 (135,9)	100,3 (197,4)	115,1 (243,4)	761,7 (1269,3)
<i>Průměrný počet příloh k příspěvkům</i>	3 (19)	0 (2)	0 (4)	2 (11)
<i>Průměrný počet příloh na studenta</i>	0,2 (1,2)	0 (0,2)	0 (0,2)	0,1 (0,7)

Tabulka 14 navazuje na tabulku 13 a vybrané indikátory interakce prezentuje i dle jednotlivých podtypů. V rámci typu B je například patrné větší zapojení učitele v těch kurzech, kde je celkově menší množství účastníků, než v kurzech s více participanty. Relativně značné rozdíly jsou rozpoznatelné v podtypech s interakcí ve tvaru hvězdy (typ C). Například u podtypu C3 (tj. interakce oběma směry) dochází k tomu, že vyučující přispívá do diskuzního fóra v průměru až trojnásobně více (19 příspěvků) než u podtypu C1 (6 příspěvků). Při zapojení dvou učitelů do interakce ve tvaru hvězdy, pak nedochází ani tak k tomu, že by se razantně snížil počet příspěvků na jednoho učitele (tj. např. na polovinu), nýbrž celkový počet příspěvků od vyučujících je vyšší (19 versus 31). Podobnost podtypu C1 a C2 z hlediska jednoduchých metrik interakce (jako např. počet příspěvků) poukazuje na nedostatečnost

těchto ukazatelů pro posouzení charakteru interakce v diskuzních fórech. Přestože na základě počtu příspěvků od učitele a od studentů bychom mohli usoudit, že jde o obdobné typy diskuze, pomocí analýzy sociálních sítí jsme odhalili, že jde o diametrálně odlišné způsoby interakce. V podtypu C1 směřují reakce primárně od studentů k učitelům, zatímco v podtypu C2 směřují primárně od učitele ke studentům. V rámci typu D pak vidíme, že k nejintenzivnější interakci (u studentů i učitelů) dochází v malých skupinách a při skupinové práci.

Tabulka 14: Vybrané základní ukazatele interakce v diskuzních fórech dle jednotlivých podtypů interakce. Opět je reportován medián a mezikvartilové rozpětí (v závorce).

	<b>Příspěvků na učitele</b>	<b>Příspěvků na stud.</b>	<b>Slov na učitele</b>	<b>Slov na studenta</b>	<b>Příloh na stud.</b>
<b>Podtypy základního typu B – malá interakce</b>					
<i>B1 – málo participantů</i>	6 (5)	2 (1,7)	294 (457,5)	102,5 (179,5)	0 (0)
<i>B2 – hodně participantů</i>	3,8 (5,8)	1,7 (1,1)	116,5 (382,2)	87,5 (185,1)	0,1 (0,6)
<i>B3 – „had“</i>	1 (0)	2,1 (0,1)	3 (0)	640,9 (95,8)	0,5 (0,1)
<b>Podtypy základního typu C – interakce ve tvaru hvězdy</b>					
<i>C1 – k učitelům</i>	6 (7)	1,9 (1,6)	251 (373)	85,5 (249,9)	0 (0,2)
<i>C2 – od učitele</i>	11 (7)	1,5 (1)	418,5 (505,2)	86,5 (106,5)	0 (0)
<i>C3 – oba směry</i>	18,8 (29,8)	2,4 (0,9)	1535,5 (2076,4)	161,8 (442,8)	0 (0,3)
<i>C4 – dva učitelé</i>	15,5 (22,2)	2,8 (5,1)	703,2 (1058)	223,1 (719)	0,1 (0,4)
<b>Podtypy základního typu D – intenzivní interakce</b>					
<i>D1 – silný střed</i>	8,5 (16,9)	6,8 (6,2)	682 (1746)	703,5 (1160,6)	0 (0,7)
<i>D2 – malá skupina</i>	16,8 (13,8)	11,8 (4,6)	2164,2 (1919,6)	1606,4 (1380,5)	0,2 (0,9)
<i>D3 – rovnoměrné zapojení</i>	6 (3,3)	4 (1,3)	182 (30,5)	311,9 (105,4)	0 (0,1)
<i>D4 – skupinová interakce</i>	42,2 (37,4)	16,6 (11,4)	3141,8 (2807,1)	854,6 (639)	6,2 (2,1)

Rozdíly v rámci vybraných SNA metrik uvádím přímo na úrovni podtypů, jelikož z hlediska struktury se poměrně zásadně liší i jednotlivé podtypy jednoho základního typu, a tudíž by bylo spíše zavádějící reportovat SNA metriky za obecné typy. Zároveň nejsou reportovány údaje za typ A, jelikož v něm nedochází k žádné interakci, a tudíž výpočet SNA metrik nedává věcně smysl.

Tabulka 15 prezentuje SNA metriky za typ B, přičemž údaje v tabulce vesměs odpovídají dosavadním poznatkům a interpretacím sítí interakce tohoto typu. V kurzech s menším

počtem participantů (B1) dochází k o něco většímu zapojení studentů i učitelů (viz počet vazeb a počet reakcí) než v kurzech s větším počtem účastníků (B2). S tím pak souvisí i rozdíly v hustotě sítí a částečně také v reciprocitě sítí. U diametru sítě je třeba zmínit, že výpočet se vztahuje jen na hlavní (největší) komponentu sítě, proto může dojít k tomu, že v podtypu B1 vychází stejný diametr jako v podtypu B2, přestože v podtypu B2 existuje řada uzlů a menších komponent bez jakékoli vazby na zbytek sítě. Extrémně vysoký diametr u podtypu B3 pak odpovídá tomu, že jde o interakci ve formě „hada“, a tudíž počet kroků, který je nutné provést, abychom se dostali z jednoho konce sítě na druhý, je velmi velký.

*Tabulka 15: SNA ukazatele interakce v diskuzních fórech dle jednotlivých podtypů základního typu B. Reportován medián a mezikvartilové rozpětí (v závorce).*

	<b>Podtyp B1</b>	<b>Podtyp B2</b>	<b>Podtyp B3</b>
<i>Průměrný diametr sítě</i>	3 (2)	3 (2)	18,5 (6,5)
<i>Průměrná hustota sítě</i>	0,2 (0,14)	0,04 (0,04)	0,05 (0,01)
<i>Průměrná reciprocita sítě</i>	0,4 (0,5)	0,12 (0,4)	0,32 (0,19)
<i>Průměrná tranzitivita sítě</i>	0 (0,43)	0 (0,05)	0 (0)
<i>Průměrný počet vazeb směřujících od učitele</i>	2 (2,3)	1 (2,8)	0 (0)
<i>Průměrný počet vazeb směřujících k učiteli</i>	1 (2)	0 (1)	0 (0)
<i>Průměrný počet vazeb směřujících od studenta</i>	1 (0,7)	0,5 (0,6)	1,1 (0,2)
<i>Průměrný počet vazeb směřujících ke studentovi</i>	1,2 (0,7)	0,6 (0,5)	1,1 (0,2)
<i>Průměrný počet reakcí směřujících od učitele</i>	2,5 (3,3)	1 (3)	0 (0)
<i>Průměrný počet reakcí směřujících k učiteli</i>	1 (4)	0 (1,5)	0 (0)
<i>Průměrný počet reakcí směřujících od studenta</i>	1,1 (1,4)	0,5 (0,7)	1,1 (0,2)
<i>Průměrný počet reakcí směřujících ke studentovi</i>	1,3 (1)	0,6 (0,6)	1,1 (0,2)

V tabulce 16 jsou uvedeny SNA metriky za čtyři podtypy základního typu C. Tyto údaje vesměs potvrzují výše uvedený popis a interpretaci jednotlivých podtypů, které vycházejí z interakce ve tvaru hvězdy, čímž zároveň potvrzují vhodnost a funkčnost navržené typologie. Zaměříme-li se nejprve na průměrný počet vazeb a reakcí, jsou jasně odlišitelné podtypy C1 a C2. Zatímco u podtypu C1 je patrné velké množství vazeb a reakcí směřujících k učiteli a zároveň minimální množství vazeb a reakcí směřujících od učitele, u podtypu C2 je tomu přesně naopak. Podtypy C3 a C4 jsou pak z hlediska průměrného počtu vazeb a reakcí velmi podobné, jejich odlišnost se však promítá v průměrné reciprocitě a tranzitivitě sítě. Jak bylo patrné výše při ukázkách sítí obou podtypů, jejich základní odlišnost pramení z toho, že

v podtypu C3 figuruje v centru sítě jeden učitel, zatímco v podtypu C4 jsou v centru učitelé dva, kteří mají navíc obvykle různé role. Tomu odpovídá vysoká reciprocita u podtypu C3, jelikož mezi jediným učitelem v centru sítě a jednotlivými studenty obvykle existují vazby v obou směrech. Naopak v podtypu C4 je to spíše tak, že k jednomu z vyučujících ve středu sítě vazby směřují, kdežto od druhého vedou ke studentům. Tím pádem nedochází tak často k recipročnímu vztahu mezi dvojicí učitel-student, a tudíž je průměrná reciprocita sítě výrazně nižší. V případě tranzitivity pak sehrává roli to, že dvojice učitelů u podtypu C4 umožňuje častější výskyt vazeb mezi trojicí uzlů (tj. učitel<sub>1</sub>-student-učitel<sub>2</sub>). Naopak u podtypu C3 existují primárně vztahy jen mezi dvojicí uzlů (učitel-student), a tudíž je průměrná tranzitivita sítě velmi nízká. Jak je ale patrné z obrázku 26 znázorňujícího příklad sítě podtypu C3, může v sítích tohoto typu občas vzniknout vazba i mezi dvěma studenty, což vede ke vzniku propojené trojice uzlů (student-učitel-student), a tudíž ani v těchto sítích není průměrná tranzitivita sítě zcela nulová (totéž ostatně platí i pro podtypy C1 a C2).

Tabulka 16: SNA ukazatele interakce v diskuzních fórech dle jednotlivých podtypů základního typu C. Reportován medián a mezikvartilové rozpětí (v závorce).

	<b>Podtyp C1</b>	<b>Podtyp C2</b>	<b>Podtyp C3</b>	<b>Podtyp C4</b>
<i>Průměrný diametr sítě</i>	3 (3)	3 (3)	7 (3,75)	6 (3,75)
<i>Průměrná hustota sítě</i>	0,09 (0,06)	0,14 (0,06)	0,17 (0,14)	0,11 (0,08)
<i>Průměrná reciprocita sítě</i>	0 (0,22)	0,29 (0,41)	0,75 (0,16)	0,29 (0,26)
<i>Průměrná tranzitivita sítě</i>	0 (0,08)	0 (0,09)	0,03 (0,18)	0,17 (0,24)
<i>Průměrný počet vazeb směřujících od učitele</i>	1 (2)	5 (2)	7,5 (6,8)	6 (2,8)
<i>Průměrný počet vazeb směřujících k učiteli</i>	8 (7,5)	1 (1,8)	6,5 (9,8)	6 (4,3)
<i>Průměrný počet vazeb směřujících od studenta</i>	1,1 (0,2)	0,4 (0,4)	1,1 (0,5)	1,5 (0,9)
<i>Průměrný počet vazeb směřujících ke studentovi</i>	0,2 (0,6)	1 (0,2)	1,1 (0,3)	1,3 (0,8)
<i>Průměrný počet reakcí směřujících od učitele</i>	1 (3)	7 (7)	12,5 (13,8)	10,5 (8,8)
<i>Průměrný počet reakcí směřujících k učiteli</i>	12 (14)	1 (2,2)	11 (20,4)	8,2 (17,7)
<i>Průměrný počet reakcí směřujících od studenta</i>	1,6 (1,3)	0,4 (0,4)	1,5 (1,1)	1,7 (3,5)
<i>Průměrný počet reakcí směřujících ke studentovi</i>	0,2 (0,7)	1,4 (0,8)	2 (1,1)	1,5 (1,2)

Poslední tabulka této výsledkové části se zaměřuje na podtypy základního typu D. I zde jsou přitom patrné rozdíly mezi jednotlivými podtypy, které potvrzují výše uvedenou

interpretaci jednotlivých podtypů a potvrzují tak navrženou typologii. Například intenzivní interakci v malé skupině (podtyp D2) odpovídá relativně nízký průměrný diametr, a naopak velmi velké hodnoty průměrné hustoty, reciprocity a tranzitivity sítě. V sítích se skupinovou interakcí (D4) je tomu do jisté míry podobně, jelikož jde také o malé skupiny s vysokou interakcí. Jelikož je ale v jedné síti těchto skupin několik, vede to k celkově nižší hustotě sítě a výrazně vyššímu diametru. Jako poměrně specifický se opět jeví podtyp D3, který má velmi nízké hodnoty průměrné hustoty a reciprocity sítě (a částečně i tranzitivity). V případě hustoty je to dáno tím, že jde o poměrně velké skupiny, kde ale většina účastníků přispívá poměrně malým množstvím příspěvků, což vede k celkově malému množství vazeb v síti. Velmi nízká reciprocita pak odpovídá tomu, že se v sítích tohoto typu objevuje jen velmi málo vzájemných vazeb mezi dvěma uzly. To dále podporuje tezi, že v těchto sítích musí jít o nějaký specifický typ zadání, jelikož v běžných sítích s vysokou mírou interakce dochází k vyššímu výskytu recipročních vazeb, a tudíž by se dalo očekávat, že celková reciprocita sítě bude vyšší.

*Tabulka 17: SNA ukazatele interakce v diskuzních fórech dle jednotlivých podtypů základního typu D. Reportován medián a mezikvartilové rozpětí (v závorce).*

	<b>Podtyp D1</b>	<b>Podtyp D2</b>	<b>Podtyp D3</b>	<b>Podtyp D4</b>
Průměrný diametr sítě	6 (3)	4 (1,5)	9 (3)	11 (3)
Průměrná hustota sítě	0,2 (0,16)	0,56 (0,36)	0,07 (0,05)	0,24 (0,11)
Průměrná reciprocita sítě	0,39 (0,36)	0,75 (0,36)	0,08 (0,04)	0,77 (0,14)
Průměrná tranzitivita sítě	0,42 (0,28)	0,84 (0,31)	0,17 (0,1)	0,58 (0,16)
Průměrný počet vazeb směřujících od učitele	3,5 (6)	6,5 (5,8)	1 (3)	9,7 (9)
Průměrný počet vazeb směřujících k učitelu	2,1 (7,4)	3,5 (4,5)	0 (3)	13,5 (4,5)
Průměrný počet vazeb směřujících od studenta	3 (2,1)	6,9 (3,7)	2,8 (1,5)	5,3 (2)
Průměrný počet vazeb směřujících ke studentovi	3,1 (2,1)	7,1 (4,5)	2,8 (1,5)	5 (2,2)
Průměrný počet reakcí směřujících od učitele	5 (14,2)	14 (12)	2 (3)	28,3 (36,8)
Průměrný počet reakcí směřujících k učitelu	3 (12,5)	4,5 (6)	0 (3)	43,3 (12,6)
Průměrný počet reakcí směřujících od studenta	4,5 (6,5)	9,1 (3)	3 (1,6)	14,5 (11,5)
Průměrný počet reakcí směřujících ke studentovi	5 (5,7)	10,2 (4)	3 (1,8)	12,9 (9,1)

## 5.5. Diskuze a závěr sondy B

Výzkumná sonda B se zaměřovala na interakce studentů a učitelů v online diskuzních fórech v LMS a na možnosti výzkumu těchto interakcí za využití analýzy sociálních sítí. Cílem sondy bylo jednak zjistit, zda je vůbec analýza sociálních sítí využitelná pro rozlišování různých forem interakce mezi studenty a učiteli v online diskuzních fórech, jednak také věcně popsat případné nalezené typy interakcí. Obecným cílem sondy pak bylo získání lepší představy o tom, nakolik je komunikace a interakce v online diskuzních fórech využívána v rámci výuky prostřednictvím systémů typu LMS. Závěry výzkumné sondy shrnuji a diskutuji v následujících podkapitolách. Nejprve podávám odpověď na každou ze stanovených výzkumných otázek, poté zmiňuji limity sondy a možné směry navazujícího či rozšiřujícího výzkumu.

### 5.5.1. Shrnutí odpovědí na stanovené výzkumné otázky

První výzkumná otázka se zaměřovala na obecné posouzení toho, nakolik jsou v rámci LMS Moodle na FF MU využívány online diskuzní fóra pro účely komunikace a interakce mezi studenty a učiteli. Tato otázka nebyla přímo řešena v rámci výsledkové části, je možné ji však nyní zodpovědět na základě výsledků týkajících se primárně zbývajících otázek. Vyjdeme-li z počtu 2739 kurzů jakožto výchozího počtu reálných kurzů probíhajících v rozmezí šesti semestrů, pak lze říci, že v 16,5 % z nich jsou alespoň nějakým (minimálním) způsobem využívána diskuzní fóra. Tomuto „minimálnímu způsobu“ pak odpovídá to, že fóra obsahují alespoň deset diskuzních příspěvků vytvořených alespoň pěti účastníky diskuze. Jak ale odhalila další analýza jednotlivých forem interakce, v jednom z identifikovaných typů (typ A) ve skutečnosti nedochází k žádné přímé interakci mezi studenty a učiteli. Pokud bychom tedy nezapočítávali kurzy s tímto typem „interakce“, pak bychom se dostali na 12,7 % kurzů využívajících online diskuzní fóra k alespoň nějaké interakci a komunikaci. V dalším z identifikovaných typů (typ B) však dochází jen k velmi malé interakci, kdy se řada studentů vůbec nezapojuje. V typu C pak dochází primárně k interakci mezi studentem a učitelem, ale jen minimálně mezi studenty navzájem. Kdybychom tedy vyloučili i kurzy s těmito dvěma formami interakce a zaměřili pozornost pouze na kurzy, kde dochází k intenzivní komunikaci jak mezi studenty a učiteli, tak i mezi studenty navzájem, pak se dostaneme pouze na hodnotu 3,9 % kurzů z celkového množství kurzů, kde dochází k využití online diskuzního fóra pro účely komunikace a interakce mezi studenty a učiteli.

V druhé výzkumné otázce byla věnována pozornost tomu, jaké strukturní formy či typy interakce v online diskuzních fórech lze odhalit pomocí analýzy sociálních sítí. Jak naznačuje již předchozí odstavec, celkem byly identifikovány čtyři základní typy interakce: 1) žádná

interakce, 2) malá interakce, 3) interakce ve tvaru hvězdy a 4) intenzivní interakce. Mimo první typ, ve kterém ve skutečnosti k žádné interakci nedocházelo, bylo dále v rámci každého typu rozlišeno několik podtypů vykazujících výrazně odlišné vlastnosti. Tak lze například v případě interakce ve tvaru hvězdy rozlišovat případy, kdy existují pouze vazby směrem k učiteli (podtyp C1), nebo naopak pouze směrem od učitele (podtyp C2). Případně je možno rozlišit, zda existují vazby oběma směry (podtyp C3) či zda ve středu oné „hvězdy“ figurují dva vyučující místo pouze jednoho (podtyp C4).

Třetí výzkumná otázka se ptala na četnostní zastoupení jednotlivých typů interakce napříč kurzy v LMS. Zde lze říci, že na úrovni základních čtyř typů interakce je zastoupení relativně rovnoměrné, jelikož každý z typů se objevuje přibližně ve čtvrtině analyzovaných kurzů. Na úrovni podtypů je pak třeba upozornit na poměrně ojedinělý výskyt některých z podtypů (zvláště podtypy B3, D3 a D4). V těchto případech lze tedy předpokládat, že jde o relativně specifický způsob využití online diskuzního fóra, který obecně není příliš rozšířen nebo se váže na nějaký specifický typ výukové aktivity. Zároveň je nutné upozornit na to, že uvedené četnostní zastoupení jednotlivých typů interakce může být do značné míry ovlivněno kontextem a vybranými analyzovanými kurzy, a tudíž nemusí být platné v jiných kontextech či v rámci jiných LMS na jiných univerzitách. Už například jen to, že se sonda zaměřovala na kurzy realizované na filozofické fakultě, může sehrávat zásadní roli, a je tudíž možné, že četnostní zastoupení jednotlivých typů interakce by bylo výrazně jiné, pokud by se jednalo o kurzy například z přírodovědné fakulty.

V souvislosti s poslední výzkumnou otázkou byly sledovány odlišnosti mezi identifikovanými formami interakce v online diskuzních fórech s ohledem na základní ukazatele interakce (jako je počet vložených příspěvků apod.) a s ohledem na vybrané SNA metriky kvantifikující určité aspekty analyzovaných sítí. Důvodem pro zařazení této otázky byla především validace identifikovaných typů a ověření smysluplnosti navržené typologie. Jednotlivé typy by totiž měly být relativně jasně rozlišitelné při pohledu na průměrné hodnoty ukazatelů interakce a zvláště SNA metrik. V opačném případě by to naznačovalo, že způsoby interakce napříč různými kurzy jsou natolik podobné či naopak odlišné, že vůbec nemá smysl hovořit o nějakých typech. Výsledky však ukázaly, že jednotlivé typy a zvláště podtypy interakce skutečně vykazují výrazně jiný charakter a má tudíž smysl hovořit o specifických typech interakce.

Jsem přesvědčen, že s ohledem na dosavadní výzkumy a publikované studie týkající se problematiky komunikace a interakce v online diskuzních fórech přináší výsledky této sondy významné obohacení dosavadního poznání. Díky analýze velkého množství kurzů totiž bylo možné odhalit takové formy interakce, kterým v dosavadní literatuře týkající se kurzů typu

SPOC zatím není věnována pozornost (srov. Brooks, Greer, & Gutwin, 2014; Ghadirian, Salehi, & Ayub, 2018; Tirado-Morueta, Maraver-López, & Hernando-Gómez, 2017). Na základě prezentovaných výsledků lze navíc říci, že se do značné míry potvrdil výše zmiňovaný názor autorek Wiseové a Paulusové (2016). Ty jsou přesvědčeny o nedostatečnosti dosavadních přístupů, které spoléhají na jednoduché metriky jako počet vložených diskuzních příspěvků či počet odstartovaných diskuzí, a upozorňují na nutnost používat sofistikovanější kvantitativní metody (jako např. analýza sociálních sítí), anebo využívat kombinaci kvantitativních a kvalitativních metod. Výsledky této sondy ukázaly, že jednoduché metriky jako počet příspěvků skutečně v některých případech nejsou schopny rozlišit strukturně zcela odlišné formy interakce v diskuzních fórech.

Odhalení zcela nových forem interakce zároveň do značné míry znemožňuje srovnání s výsledky dosavadního výzkumu. Přesto lze zmínit alespoň určité styčné plochy. Nabízí se např. srovnání s výše představenou typologií Knowltona (2005), který rozlišuje pět forem participace v online diskuzních fórech. V souvislosti s pasivní participací přitom hovoří o takovém využití diskuzního fóra, kdy fórum vůbec není vnímáno jako prostor pro interakci mezi studenty. V souvislosti s generativní formou participace pak hovoří o takové interakci v diskuzním fóru, kdy dochází primárně k reagování na zadání či příspěvky vyučujícího, zatímco příspěvkům ostatních studentů není věnována pozornost. To do značné míry odpovídá typům A a C. V typu A vůbec nedochází k interakci mezi účastníky diskuze a v typu C dochází především k interakci mezi vyučujícím a jednotlivými studenty, ale nikoli mezi studenty navzájem. Výsledky sondy jsou rovněž do určité míry v souladu s výzkumem autorů Tirado-Morueta, Maraver-López a Hernando-Gómez (2017). Ti poukazovali na to, že se míra i způsob interakce mění v závislosti na typu úkolu (či zadání), na kterém studenti v diskuzních fórech pracují. V rámci sondy sice nebyla věnována přímá pozornost typu úkolu, přesto se zdá, že přinejmenším některé ze specifických podtypů interakce (např. B3 a D3) jsou odrazem určitého (typu) zadání či výukové aktivity, bez kterého by ke vzniku sítí interakce v této podobě nedošlo. Určité paralely s dosavadním výzkumem nabízí dále podtyp D1, který se zdá mít nejbližší k formám interakce, jež jsou obvyklé spíše v neformálním vzdělávání či v kurzech typu MOOC. Způsob vzniku sítí tohoto typu se totiž zřejmě řídí principem preferenčního připojování, jehož výskyt potvrdili ve své simulační studii Zhangová, Skryabin a Song (2016), kteří analyzovali síť interakce v diskuzních fórech v MOOC.

Závěrem je třeba znovu explicitně zmínit, že v rámci sondy B byla pozornost zaměřena pouze na kurzy probíhající v LMS Moodle na Filozofické fakultě Masarykovy univerzity. Vedle doménových či oborových specifik spojených s kurzy na Filozofické fakultě Masarykovy univerzity (viz výše), je dále třeba mít na paměti především to, že většina kurzů má charakter



blended kurzů (srov. Švaříček & Zounek, 2008). Je tak možné, že identifikované formy interakce jsou specifické pro blended kurzy a že při zaměření pozornosti výhradně na online kurzy bychom odhalili více či méně odlišné typy interakce v diskuzních fórech. Velké zastoupení blended kurzů v analyzovaných datech zároveň vrhá poněkud odlišné světlo na výsledky vztahující se k první výzkumné otázce, která se zaměřovala na obecné posouzení míry využívání online diskuzních fór pro účely komunikace a interakce mezi studenty a učiteli. V blended kurzech kombinujících tradiční prezenční výuku s výukou v online prostředí je totiž možné naplánovat různé typy výukových aktivit do různých výukových prostředí (tj. online versus off-line). Lze tedy očekávat, že nemalá část vyučujících má své blended kurzy koncipované tak, že komunikace a interakce mezi studenty probíhá primárně v průběhu prezenčních setkání, zatímco aktivity v online kurzech v LMS směřují k jiným výukovým cílům. Výše uvedené množství kurzů využívajících diskuzní fóra, které se na první pohled může zdát poměrně malé, je tak v tomto světle poměrně pochopitelné.

### **5.5.2. Limity sondy a možnosti dalšího výzkumu**

V samotném závěru zmíním alespoň několik limitů sondy B, které zároveň otevírají prostor pro další výzkum. V první řadě je třeba zdůraznit, že se sonda zaměřovala pouze na interakci a komunikaci v online diskuzních fórech. To je přitom pouze jedno z míst, kde v rámci blended kurzů i v rámci systémů pro řízení výuky může probíhat interakce mezi studenty a učiteli. Již bylo naznačeno, že v kontextu blended kurzů je třeba počítat nejen s interakcí v online prostředí, ale rovněž s přímou interakcí tváří v tvář (*face-to-face*). Dále je však třeba počítat s tím, že v LMS může probíhat interakce mezi studenty i mimo diskuzní fóra. Např. pro účely synchronní online komunikace je v LMS Moodle (ale i v jiných LMS) dostupný nástroj *Chat*. Navíc k interakci mezi studenty může docházet i v dalších typech nástrojů, které sice nejsou primárně určeny pro účely interakce, ale přesto dovolují vzájemnou komunikaci mezi studenty prostřednictvím komentářů (v LMS Moodle lze zmínit např. nástroje *Databáze*, *Slovník* či *Wiki*). Ke komunikaci mezi vyučujícím a studenty stejně jako mezi studenty navzájem může také docházet prostřednictvím přímých zpráv, a to ať již v prostředí LMS, nebo zcela mimo LMS (např. prostřednictvím e-mailu). Např. formy interakce typu C (tj. interakce ve tvaru hvězdy) identifikované v diskuzních fórech by stejně dobře mohly probíhat prostřednictvím e-mailu. Je tak třeba si uvědomit, že analyzovaná data pocházející z online diskuzních fór zachycují vždy nutně pouze část celkového souhrnu interakcí mezi studenty a učiteli, ke kterému v průběhu kurzu dochází.

Dalším zásadním limitem, na který ostatně v souvislosti s interakcí v online diskuzních fórech upozorňuje řada autorů (např. Hernández-García, González-González, Jiménez-

Zarco, & Chaparro-Peláez, 2015; Wise & Cui, 2018; Wise, Hausknecht, & Zhao, 2014), je to, že se sonda zaměřovala pouze na „aktivní“ zapojení studentů do diskuzních fór. Aktivním zapojením přitom bylo chápáno vložení vlastního diskuzního příspěvku do online fóra. Poměrně důležitou roli však zřejmě sehrává i „pasivní“ zapojení studentů do diskuzních fór, tj. situace, kdy student sleduje příspěvky v diskuzních fórech, ale sám vlastní příspěvek nekládá. Jak upozorňuje Hernández-García et al. (2015), v řadě situací vůbec nemusí platit, že chybějící „aktivní“ zapojení studenta znamená pasivního studenta. Naopak studenti mohou být velmi silně zapojeni do diskuze už jen tím, že sledují probíhající diskuzi a studují příspěvky ostatních. I toto „pasivní“ zapojení tak může ve skutečnosti být aktivitou s vysokou kognitivní náročností (srov. Wise, Hausknecht, & Zhao, 2014) a může být zcela zásadní pro učení prostřednictvím online diskuzních fór. Jako důležitý směr dalšího výzkumu se tak jeví rozvoj metod a postupů, které by alespoň v určité míře dovolovaly zachytit i ono „pasivní“ zapojení studentů v diskuzních fórech.

Posledním důležitým limitem prezentované sondy a zároveň širokým prostorem pro další výzkum je vývoj interakce mezi studenty a učiteli v čase resp. v průběhu kurzu. Realizovaná sonda totiž nabízí pouze statický pohled na interakci v diskuzních fórech jelikož se zaměřovala na analýzu interakce jakožto statické sítě vztahů mezi účastníky diskuze existující po skončení kurzu<sup>121</sup>. Interakce v diskuzních fórech je však ze své podstaty dynamickým procesem, jenž tudíž nebyl v rámci analýzy plně reflektován. Výsledky analýzy tak nutně poskytují zjednodušený pohled na interakci v diskuzních fórech. Je například možné, že sítě interakce mezi studenty a učiteli, které na konci kurzu mají obdobnou strukturu, a tudíž dle výsledků analýzy spadají do stejného typu či podtypu, se ve skutečnosti v průběhu kurzu vyvíjely odlišným způsobem. To však při statickém pohledu na výslednou síť zůstane neodhaleno. Nabízí se tak věnovat výzkumnou pozornost vývoji a proměnám různých interakčních vzorců v čase. Ačkoli dynamickým aspektům interakce v online diskuzních fórech zatím příliš pozornosti věnováno není, například studie Zhangové, Skryabina a Songa (2016) poukazuje na potenciál tohoto směru výzkumu.

---

<sup>121</sup> Představíme-li si interakci studentů a učitelů v online diskuzním fóru jako síť postupně se vyvíjející v čase, pak se tato síť bude lišit podle toho, v jaký čas se na ni budeme dívat. V rámci této sondy byla vždy analyzována finální podoba sítě, tzn. podoba sítě v době, kdy už se síť dále nevyvíjí (nepřibývají v ní noví aktéři či nové vazby), jelikož již došlo ke skončení kurzu.

## 6. Sonda C - Analýza chování studentů v průběhu plnění online testů s využitím metody dolování procesů<sup>122</sup>

Ačkoli je využívání systémů pro řízení výuky (LMS) zvláště na univerzitách a vysokých školách již poměrně běžné (srov. Ferguson, 2012a; Macfadyen & Dawson, 2012; Poulová, 2010), učitelé využívající LMS ve své výuce mají relativně často jen omezené možnosti sledovat, co přesně se v jejich online kurzech děje. Ať již jde o to, jak se v kurzech studenti chovají, jakým způsobem přistupují ke studiu online materiálů či jak postupují při plnění výukových aktivit. Důvodem je to, že běžné systémy typu LMS prozatím stále neobsahují nativní analytické či data miningové nástroje umožňující učitelům snadno a rychle získat vhled do dění v kurzu. Existují sice různé specializované externí nástroje, které jsou schopny dát vyučujícím potenciálně přínosné výstupy, obvykle jsou však pro učitele příliš komplexní, jelikož jsou určeny primárně pro výzkumníky a nabízí proto příliš širokou nabídku funkcí významně přesahující potřeby učitelů (srov. Romero, Ventura, & García, 2008; Romero & Ventura, 2010; Romero, Cerezo, Bogarín, & Sánchez-Santillán, 2016). Otázky související s rozvojem nových analytických a data miningových nástrojů a přístupů, které by učitelům umožnily jednoduše, a přitom podrobně sledovat chování a interakci studentů při vykonávání online výukových aktivit, jsou stále na pořadu dne a tvoří významnou část výzkumu v oblasti analytiky učení a data miningu ve vzdělávání (viz kapitolu 2.3.1. *Analytické nástroje pro sumarizaci a vizualizaci dat*).

Nemožnost dostatečně podrobně sledovat, jak se studenti při učení v LMS chovají, může přitom mít poměrně zásadní důsledky především v kontextu hodnocení online aktivit studentů. Ačkoli je (především) v oblasti data miningu ve vzdělávání věnována problematice chování studentů v online prostředí poměrně velká pozornost (srov. Papamitsiou & Economides, 2014 či Peña-Ayala, 2014b, ale také kapitolu 2.3.3.2. *Modelování chování studentů*), většina výzkumů se zaměřuje na analýzu dat pocházejících z inteligentních tuteurských systémů (ITS), spíše než ze systémů typu LMS (viz Baker & Gowda, 2010; Baker, Goldstein, & Heffernan, 2011; Muldner, Burleson, Van de Sande, & VanLehn, 2011). Pokud už se výzkumy zaměřují přímo na systémy typu LMS, věnují pozornost zejména predikci úspěchu studentů či identifikaci rizikových studentů (např. Smith, Lange, & Huston, 2012; Jayaprakash, Moody, Lauría, Regan, & Baron, 2014; Baker, Lindrum, Lindrum, & Perkowski, 2015), případně se pohybují spíše na obecnější úrovni a sledují chování studentů v průběhu

---

<sup>122</sup> Tato kapitola vychází z autorem publikované studie s názvem *Using process mining to analyze students' quiz-taking behavior patterns in a learning management system* (Juhaňák, Zounek, & Rohlíková, 2019).

celého kurzu (např. Agudo-Peregrina, Iglesias-Pradas, Conde-González, & Hernández-García, 2014; HersHKovitz & Nachmias, 2011).

Výrazně méně často se však výzkumy zaměřují na detailní analýzu interakcí studentů v kontextu konkrétních výukových aktivit v LMS (Phillips et al., 2011) či dokonce specificky na analýzu chování studentů v rámci aktivit sloužících k hodnocení (Papamitsiou & Economides, 2016). Přitom se stále více ukazuje, že právě specifický kontext, ve kterém online učení a výuka probíhá, je pro porozumění chování studentů zcela zásadní. A bez dostatečného zohlednění kontextu (tj. nejen konkrétní technologie či nástroje, ale také způsobu jejich zapojení do výuky), zřejmě nelze budovat fungující, a přitom dostatečně obecné prediktivní modely použitelné v analytických či data miningových nástrojích pro učitele (Gašević et al., 2016).

V této sondě se proto zaměřuji právě na problematiku chování studentů v systémech typu LMS. Konkrétně přitom zaměřuji pozornost na jeden určitý typ výukových aktivit sloužících pro účely hodnocení, jelikož se věnuji specificky chování studentů v průběhu plnění online testů. Pro analýzu chování studentů je přitom využita metoda dolování procesů (*process mining*). Ta prozatím patří spíše mezi méně vyžívané metody v kontextu analytiky učení a data miningu ve vzdělávání. Dosavadní studie využívající tuto metodu v kontextu systémů pro řízení výuky (Romero, Cerezo, Bogarín, & Sánchez-Santillán, 2016) a dokonce i přímo v souvislosti s analýzou online testů (Papamitsiou & Economides, 2016) však naznačují potenciál využití této metody právě pro účely mapování a modelování procesu vyplňování online testů studenty. Cílem sondy je proto především zhodnocení, nakolik je metoda dolování procesů využitelná pro účely analýzy chování studentů v průběhu plnění online testů a případně pro účely detekce specifických forem chování studentů při plnění testů v LMS.

## 6.1. Přehled dosavadních výzkumů k sondě C

V úvodu sondy C a stejně tak v kapitole 2.3.3.2. *Modelování chování studentů* byla problematika analýzy resp. modelování chování studentů v různých online vzdělávacích systémech (LMS, ITS apod.) spojována především s oblastí data miningu ve vzdělávání a analytiky učení, kde je této problematice v současnosti věnována značná pozornost. Zaměříme-li se však na chování studentů přímo v průběhu vyplňování online testů, zjistíme, že je tomuto tématu věnována pozornost i v jiných kontextech a mimo výzkumné oblasti data miningu ve vzdělávání a analytiky učení. Chování studentů při plnění testů (tzv. *quiz-taking behavior*) může mít totiž zásadní důsledky pro validitu testů, a tudíž i hodnocení studentů. Proto je možností odhalování různých typů neobvyklého či nestandardního chování studentů v průběhu plnění testů věnována pozornost i v širší oblasti hodnocení studentů

(*student assessment*) a v oblasti didaktických testů. V souvislosti s hodnocením či testováním prostřednictvím systémů typu LMS se pak obvykle hovoří o oblastech označovaných jako online hodnocení (*online assessment*), počítačové hodnocení (*computer-based assessment*) či elektronické hodnocení (*electronic assessment*) (srov. Buchanan, 2002; Gaytan & McEwen, 2007; Kim, 2015; Terzis & Economides, 2011; Whitelock, 2006).

Při mapování dosavadního výzkumu chování studentů v průběhu plnění online testů resp. problematiky detekce specifických či nestandardních forem chování při vyplňování online testů považují proto za nezbytné poskytnout širší přehled a věnovat pozornost i dalším oblastem mimo data mining ve vzdělávání a analytiku učení. Konkrétně tak v rámci přehledu dosavadních výzkumů nastíním tři základní skupiny přístupů k analýze chování studentů při plnění online testů:

1. přístupy založené na tzv. *person-fit* indexech,
2. přístupy založené na rychlosti odpovídání a
3. přístupy vycházející z data miningu ve vzdělávání a z analytiky učení.

Než se však přesunu k představení jednotlivých přístupů, je nutné provést vymezení několika základních pojmů souvisejících s různými typy testů. Důvodem je jednak to, že tyto pojmy budou dále v textu používány, jednak také to, že v různých typech testů se mohou vyskytovat odlišné formy chování studentů, a tudíž se v souvislosti s různými typy testů objevují různé způsoby detekce a modelování chování studentů při jejich plnění.

Předně je třeba rozlišit formativní a sumativní hodnocení. Cílem formativního či průběžného hodnocení je obvykle získat informaci o aktuálním stavu určitého aspektu učení již v průběhu učebního procesu. Zjišťovaným aspektem učení pak může být např. aktuální výkon studentů, zjišťování porozumění určitému problému, identifikace typických chyb apod. Formativní hodnocení slouží především jako podpora učení a pomůcka pro zlepšování výkonu studentů. Naopak cílem sumativního hodnocení není již ani tak podpora učení, jako spíše zhodnocení výsledku učebního procesu, tj. zjištění, zda student dosáhl požadované úrovně znalostí (Kim, 2015; Průcha, Walterová, & Mareš, 2003, 2009).

V kontextu online hodnocení a systémů typu LMS je pak jedním z nejčastěji využívaných způsobů realizace formativního i sumativního hodnocení v LMS nástroj pro tvorbu testů, kvízů či cvičení. V oficiálním českém překladu systému Moodle je pro tento nástroj použito označení *Test*, v originálním anglickém znění se pak využívá pojem *Quiz*. V tomto ohledu je nutno upozornit na relativně široké a nejednoznačné pojetí pojmu „test“ v českém kontextu. Je-li řeč o „testech“ v odborné pedagogické literatuře, mají se tím obvykle na mysli didaktické

testy<sup>123</sup>. Didaktický test je pak zpravidla chápán jako zkouška orientující se na objektivní zjišťování úrovně zvládnutí učiva (Chráska, 1999; Maňák, Švec, & Švec, 2005), případně jako nástroj pro systematické měření výsledků výuky (Byčkovský, 1982). Tato pojetí směřují primárně k sumativnímu hodnocení a ověřování úrovně znalostí. Při zaměření pozornosti na obecné porozumění pojmu „test“ v pedagogické praxi však zjistíme, že jsou pod tento pojem zahrnovány i další typy aktivit, které mají blíže spíše k formativnímu hodnocení a jejichž primárním účelem je spíše podpora učení než měření znalostí. S oporou o anglickou terminologii tak může být vhodné rozlišovat mezi testy (*tests*) a kvízy (*quizzes*). Zatímco o testech se hovoří primárně v kontextu sumativního hodnocení, označení „kvízy“ se používá spíše v rámci formativního hodnocení (Peat & Franklin, 2002; Kibble, 2007). V českém odborném kontextu však toto rozlišení není běžné, proto dále používám pouze označení „test“ a případně rozlišuji, zda mám na mysli test pro účely formativního či sumativního hodnocení.

Posledním důležitým rozlišením, které je třeba nyní provést, je rozlišení na tzv. *low-stakes* a *high-stakes* testy. Toto rozlišení je založeno na tom, jaké mají výsledky testu důsledky pro testovaného studenta. Výsledky *low-stakes* testů obvykle nemají žádné nebo jen minimální důsledky pro testovaného studenta, zatímco výsledky *high-stakes* testů (v češtině také tzv. rozhodných testů) jsou z hlediska důsledků pro studenta velmi důležité či zcela zásadní. Příkladem *high-stakes* testů může být např. postupová zkouška, bez jejíhož splnění nemůže student pokračovat dále ve studiu. Příkladem *low-stakes* testu může být např. průběžný test, který se nepodílí na výsledné známce za kurz. *Low-stakes* testy tak bývají obvykle spojovány spíše s formativním hodnocením, zatímco *high-stakes* testy s hodnocením sumativním (Davis, 2013, Zhang & Henderson, 2015).

### **6.1.1. Přístupy založené na person-fit indexech**

Jedním z přístupů, který je používán především v oblasti sumativního hodnocení a *high-stakes* testů, je přístup založený na tzv. person-fit indexech. V českém prostředí této problematice zatím není věnována přílišná pozornost. Krátce se jí věnují snad jen Jelínek, Květon a Vobořil (2011), kteří hovoří o PF (person-fit) indexech umožňujících odhalovat nekonzistentní testové chování. Zároveň zmiňují, že „mimo oblast osobnostních dotazníků lze PF indexy využít i v oblasti výkonových testů, například k identifikaci v testu podvádějících osob nebo ke zjištění osob se specifickými schopnostmi a diagnóze kognitivních chyb konkrétních probandů“ (Jelínek, Květon, & Vobořil, 2011, s. 83).

---

<sup>123</sup> Druhou významnou oblastí, kde se v pedagogice a zvláště pedagogickém výzkumu pracuje s pojmem „test“, je samozřejmě statistika s různými typy statistických testů. Toto využití pojmu „test“ však nyní není předmětem zájmu.

Analýzy založené na person-fit indexech mají již poměrně dlouhou tradici a jsou využívány nejen pro účely hodnocení studentů (tj. v rámci pedagogické evaluace), ale také (a možná i primárně) v oblasti psychologického hodnocení, tj. např. u osobnostních testů, měření postojů apod. (Meijer & Sijtsma, 2001; Rupp, 2013). Person-fit metody jsou rozvíjeny především v rámci tzv. *item response theory* (IRT) neboli teorie odpovědi na položku. Obecně lze přitom říci, že se používají pro zhodnocení toho, nakolik je individuální výkon studenta na jednotlivých položkách testu v souladu či naopak nesouladu s určitým IRT modelem resp. s výkony ostatních studentů, kteří vyplňovali daný test. Zjednodušeně řečeno jsou person-fit indexy využívány ke zhodnocení toho, nakolik je způsob vyplňování testu studentem očekávatelný či „normální“ a nakolik je neobvyklý, nestandardní či neočekávaný (Meijer, Niessen, & Tendeiro, 2016).

Vezmeme-li si pro ilustraci didaktický test, tak výsledné skóre určitého žáka nemusí být vždy adekvátní vzhledem k jeho skutečným znalostem. To znamená, že v určitých případech nemusí didaktický test správně změřit skutečné znalosti žáka. Nepřesnost měření samozřejmě může být dána mnoha faktory. Nechme nyní stranou faktory týkající se samotného testu i jeho konstrukce a zaměřme se na faktory týkající se osoby vyplňující test. Student může v průběhu testu např. hádat (tzv. *guessing behavior*) a uměle si tak navyšovat výsledné skóre. Nebo naopak může student trpět tzv. *test anxiety* čili trémou či úzkostí spojenou s vyplňováním testu. V takovém případě student kvůli přílišné nervozitě či strachu z neúspěchu odpovídá špatně i na otázky testující ty znalosti, které ve skutečnosti má. Student také nemusí být dostatečně seznámen s formátem testu (tzv. *test unfamiliarity*), což může ve výsledku způsobit nižší skóre, než by odpovídalo skutečným znalostem. Jiným příkladem může být tzv. *“sleeping” behavior*, kdy má student problémy s odpovídáním na první otázky v testu. Samozřejmě může docházet i k různým formám podvádění (*cheating*), kdy je skóre studenta uměle navyšováno např. tím, že došlo k prozrazení správných odpovědí na otázky v testu, anebo student získal správnou odpověď od jiného studenta vyplňujícího stejný test apod. (Emons, Sijtsma & Meijer, 2005; Meijer & Sijtsma, 2001).

Takové specifické případy chování při vyplňování testu pak mohou ústit právě v neobvyklý či nestandardní způsob vyplňování resp. v nestandardní vzorec odpovědí<sup>124</sup>, což způsobuje neadekvátní výsledky studentů v testu. Person-fit analýzu je pak možné využít právě pro odhalování těchto neobvyklých případů, u kterých může být výsledné skóre nevalidní a u kterých tudíž mohlo docházet k některému z výše uvedených typů chování v průběhu vyplňování testu.

---

<sup>124</sup> V anglicky psané literatuře se v této souvislosti používá spojení „aberrant item response pattern“.

Podrobný popis jednotlivých person-fit indexů a způsobu jejich výpočtu jde již nad rámec této sondy, pro základní přehled lze ale odkázat na metodologickou přehledovou studii Meijera a Sijtsmy (2001), kteří podávají přehled širokého spektra používaných person-fit indexů. Je však nutné zmínit, že při výpočtech person-fit indexů se vychází pouze ze skóre studentů na jednotlivých položkách testu. Pracuje se tedy pouze s informací o správnosti či nesprávnosti studentovy odpovědi na jednotlivé otázky testu a jiné okolnosti nejsou brány v úvahu. Obecný princip výpočtu většiny person-fit indexů lze pak zjednodušeně vysvětlit jako kvantifikaci toho, nakolik student zodpovídá obtížné testové položky správně a jednoduché testové položky nesprávně (viz Meijer & Sijtsma, 2001; Meijer, Niessen & Tendeiro, 2016).

Z hlediska praktického využití pro detekci různých typů chování studentů v průběhu vyplňování testů má však přístup založený na person-fit indexech několik nevýhod. Především, person-fit indexy jsou citlivé na řadu různých typů neobvyklého chování, přičemž výše byly zmíněny příklady jen některých z nich (další uvádí např. Rupp, 2013). Person-fit indexy lze tak sice využít pro detekci neobvyklého chování při plnění testu, ovšem u většiny z nich nelze na základě samotného person-fit indexu určit, o který typ netradičního či neobvyklého chování se jedná. Pro řešení tohoto problému tak např. Emons, Sijtsma & Meijer (2005) navrhují analytický postup, kde je zapojena grafická analýza (*graphical analysis*) a lokální analýza (*local analysis*), jež umožňují hlubší vhled do možných příčin daného neobvyklého chování. Podrobnější popis tohoto analytického postupu jde však již za rámec této sondy.

### **6.1.2. Přístupy založené na rychlosti odpovídání**

Zatímco přístupy založené na person-fit indexech mají již relativně dlouhou historii a jsou využívané i mimo oblast počítačového testování, přístupy založené na rychlosti odpovídání začaly získávat na větší popularitě jednak s rozvojem počítačového testování (CBT), jednak s rozvojem inteligentních tutorských systémů (ITS). V souvislosti s tím můžeme zároveň sledovat dvě do určité míry paralelní oblasti výzkumu. Na jedné straně rozvíjeli tento typ přístupů výzkumníci věnující se primárně problematice testování, kteří pocházejí zejména z oblasti psychologie a pedagogiky (např. Wise & Kong, 2005; Wise, Kong & Pastor, 2009). Na druhé straně jsou pak výzkumníci pracující primárně s daty z inteligentních tutorských systémů, tedy pocházející spíše z oblastí jako informatika a data mining (např. Beck, 2005; Mostow, Beck, Cuneo, Gouvea, & Heiner, 2005). Druhý ze zmiňovaných výzkumných směrů lze přitom do značné míry považovat za jeden z hlavních inspiračních zdrojů současných výzkumů v oblasti data miningu ve vzdělávání.



Ačkoli se terminologie ve zmiňovaných oblastech poněkud liší, základní myšlenka přístupů založených na rychlosti odpovídání je obdobná a vychází z možností nástrojů počítačového testování (resp. ITS), které dovolují přesně zaznamenávat čas od zobrazení konkrétní úlohy v testu po zadání odpovědi studentem<sup>125</sup>. Z hlediska odpovídajícího studenta se pak obvykle očekává, že v zásadě volí jednu z následujících dvou strategií:

1. Buď se aktivně snaží určit správnou odpověď na zadanou úlohu (tzv. *solution behavior* resp. *solution-seeking behaviour*),
2. anebo pouze (rychle) vybírá některou z odpovědí, aniž by se aktivně snažil zjistit, jaká odpověď je správná (tzv. *guessing behavior* resp. *rapid-guessing behavior*).

Délka odpovědi (tj. *item response time*) pak může být využita právě pro rozlišení mezi standardním chováním spojeným se snahou správně zodpovědět zadanou úlohu (*solution behavior*) a naopak nestandardním chováním spojeným s tipováním správné odpovědi (*rapid-guessing behavior*). Za tímto účelem tak Wise a Kong (2005) zavedli metriku označovanou jako *response time effort* (RTE), která byla posléze využívána různými autory i v mnoha dalších studiích (např. Wise, Kong & Pastor, 2009; Slim, Must, & Täht, 2013; Lee & Jia, 2014).

Určitou nevýhodou RTE a obdobných metrik založených na rychlosti odpovídání je ovšem to, že je nutné pro každou z testových úloh stanovit konkrétní práh, který určuje, jaká rychlost bude považována za standardní chování a kdy už naopak půjde o nestandardní chování (Wise & Kong, 2005). Přičemž přístupy k určení odpovídajících prahů mohou být různé, a ne vždy dostatečně dobře automatizovatelné. Navíc, jak je z výše uvedeného patrné, z hlediska detekce různých typů chování studentů v průběhu plnění testů je využití čistě časového přístupu problematické, jelikož lze pomocí těchto přístupů detekovat vesměs jen dva obecné typy chování (tj. *solution behavior* vs. *rapid-guessing behavior*). Zvláště v kontextu výzkumů věnujících se inteligentním tutorským systémům se tak postupně indikátor délky odpovědi (tj. *response time*) začal využívat pouze jako jeden z více různých faktorů vstupujících do komplexnějších modelů (např. Romero & Ventura, 2007).

### **6.1.3. Přístupy vycházející z data miningu ve vzdělávání a analyticky učení**

Jak bylo uvedeno v úvodu sondy, detekce a modelování různých typů chování studentů v online výukových prostředích je zvláště v data miningu ve vzdělávání jednou ze stěžejních

---

<sup>125</sup> V anglicky psané literatuře se v této souvislosti používá spojení „item response time“ či jen „response time“.

oblastí zájmu výzkumníků. Dle přehledové studie Peña-Ayaly (2014b) se přímo problematice modelování chování studentů (*student behavior modeling*) věnuje více jak 21 % výzkumných publikací, přičemž modelování studentů obecně se v určitém ohledu věnuje dokonce 82 % výzkumů. Předmětem modelování chování studentů jsou přitom v dosavadních výzkumech různé typy chování, jako například:

- hádání či tipování (tzv. *guessing behavior*)
- chování označované jako “*sleeping*” *behavior* (viz výše)
- chování označované jako *gaming the system*, které by šlo přeložit jako obcházení systému (viz kapitola 2.3.3.2.),
- chování spojené s hledáním pomoci (*help-seeking behavior*) či naopak se zneužíváním pomoci resp. nápovědy (*misusing help*) a další (Baker & Inventado, 2014; Peña-Ayala, 2014a).

Z hlediska doposud používaných metod jsou přitom pro identifikaci různých forem chování studentů využívány především metody shlukování a klasifikace (Bousbia & Belamri, 2014).

Co se týká přímo metody dolování procesů, je tato metoda zmíněna již v první stěžejní publikaci týkající se data miningu ve vzdělávání (*Handbook of Educational Data Mining*) jakožto jedna ze základních technik používaných v této oblasti (viz Romero, Ventura, Pechenizkiy, & Baker, 2010). Zároveň je ale zmíněna jakožto metoda, která zatím není příliš využívána, jelikož dosavadní přístupy v kontextu data miningu ve vzdělávání se jen zřídka zaměřují na proces jako celek (viz Trčka, Pechenizkiy, & van der Aalst, 2010). Přesto metoda dolování procesů získává postupně i v oblasti vzdělávání určitou pozornost výzkumníků. Dolování procesů a jeho možné využití ve vzdělávání představují např. Reimann a Yacefová (2013). Ve svém kritickém příspěvku se pak Reimann, Markauskaiteová a Bannertová (2014) věnují metodě dolování procesů z pohledu metodologických výzev spojených s datově intenzivními výzkumnými metodami.

Zaměříme-li pozornost přímo na empirické studie, lze zmínit především využití dolování procesů v kontextu počítačem podporovaného kolaborativního učení (*computer-supported collaborative learning – CSCL*), kde jej Schoorová a Bannertová (2012) využily pro mapování sociálních regulačních procesů. Autoři zároveň dochází k závěru, že metody dolování procesů se ukázaly jako užitečné pro získání vhledu do samotného procesu učení a doporučují využití těchto metod pro další analýzy. Zajímavé využití dolování procesů nabízí i Bannertová, Reimann a Sonnenberg (2014), kteří se ve své studii věnují problematice seberegulovaného učení a využívají metody dolování procesů na původně kvalitativních datech získaných pomocí think-aloud protokolu. Aplikaci dolování procesů na datech pocházející z prostředí LMS

Moodle se pak věnují např. Romero et al. (2016). Přímou v souvislosti s problematikou chování studentů v průběhu plnění online testů využívají metodu dolování procesů Papamitsiouová a Economides (2016). Konkrétně se autoři zaměřují na využití dolování procesů pro detekci chování spojeného s hádáním či tipováním (*guessing behavior*). A ačkoli pracují s daty pocházejícími ze systému vlastní výroby, což může mít jisté důsledky z hlediska přenositelnosti na jiné systémy, výsledky jejich studie naznačují, že využití metody dolování procesů může přinést nové možnosti v oblasti detekce a modelování různých typů chování studentů v průběhu vyplňování online testů v rámci systémů typu LMS.

## 6.2. Výzkumný problém a otázky sondy C

Výzkumný problém této sondy se zaměřuje na možnosti využití metody dolování procesů pro analýzu chování studentů v rámci systému pro řízení výuky (LMS), specificky pak na analýzu chování studentů v průběhu vyplňování online testů. Primárním cílem sondy je tak především obecné zhodnocení využitelnosti metody analýzy procesů pro tento typ výzkumného problému. Sekundárním cílem je pak zmapování a popis případných specifických způsobů chování studentů při plnění online testů, které se podaří za využití dolování procesů odhalit. Hlavní výzkumnou otázku (HVO) této sondy lze tak formulovat následovně:

- *HVO: Jak je využitelná metoda dolování procesů pro účely detekování specifických způsobů chování studentů v průběhu plnění online testů v LMS?*

Výše uvedenou hlavní výzkumnou otázku jsem přitom pro účely řešení sondy C rozdělil na následující tři specifické výzkumné otázky (SVO):

- *SVO1: Zda a případně nakolik je využitelná metoda dolování procesů pro analýzu a detekci různých forem chování studentů v průběhu plnění online testů v LMS Moodle?*
- *SVO2: Jaké způsoby chování studentů v průběhu plnění online testů v LMS Moodle lze detekovat za využití dolování procesů?*
- *SVO3: Jaké je četnostní zastoupení jednotlivých forem či způsobů chování studentů v průběhu plnění online testů v LMS Moodle?*

Jak ukázal přehled dosavadního výzkumu, prozatím je k dispozici jen velmi málo studií využívajících dolování procesů jakožto metodologický přístup. Zvláště pak, pokud se zaměříme přímo na systémy typu LMS a následně pouze na aktivitu studentů v průběhu plnění online testů. Analýze chování studentů při plnění testů za použití dolování procesů se

věnují jen Papamitsiouová a Economides (2016). Ti se však zaměřují pouze na využití dolování procesů pro detekci chování spojeného s hádáním či tipováním (*guessing behavior*). Přímo v kontextu LMS Moodle využívají dolování procesů Romero et al. (2016), nevěnují však pozornost přímo procesu vyplňování online testů, nýbrž sledují spíše chování studentů v kurzu jako celku. Otázka po možnostech využití metody dolování procesů pro analýzu a detekci různých forem chování studentů v průběhu plnění online testů v LMS Moodle tak zůstává stále otevřená, a proto se na ni zaměřuje první specifická výzkumná otázka.

Druhá otázka se zaměřuje na potenciálně odhalitelné způsoby chování studentů v průběhu plnění testů. Jak bylo zmíněno výše, Papamitsiouová a Economides (2016) se zaměřují pouze na tzv. *guessing behavior*. V přehledu dosavadních výzkumů však byla uvedena řada dalších typů chování, kterým výzkumníci věnují pozornost v souvislosti s plněním online testů (viz Baker & Inventado, 2014; Emons, Sijtsma & Meijer, 2005; Meijer & Sijtsma, 2001; Peña-Ayala, 2014a; Wise & Kong, 2005). Doposud však zřejmě neexistují studie, jež by zjišťovaly, které z těchto dalších typů chování studentů v průběhu plnění testů jsou detekovatelné za využití metody proces miningu. Na tento problém se proto zaměřuje druhá specifická výzkumná otázka číslo 2.

Poslední specifickou výzkumnou otázkou (SVO3) lze pak chápat především jako rozšíření SVO2, jelikož se zaměřuje na četnost výskytu jednotlivých forem či způsobů chování v průběhu plnění testů. Vzhledem k doposud chybějícímu výzkumu totiž k tomuto zatím nemáme žádné informace.

## **6.3. Metodologie sondy C**

Sonda C má vzhledem ke stanoveným cílům především exploratorní povahu, kdy se za využití relativně inovativních metod dolování procesů snaží odhalit a zmapovat způsoby chování studentů v průběhu plnění online testů v systémech typu LMS, a to na datech z vybraných online testů různých typů. V následujících metodologických podkapitolách nejprve představím dolování procesů jakožto základní metodologický přístup této studie, následně popíši analyzovaná data resp. jednotlivé testy, kterým byla v rámci sondy C věnována pozornost. V posledních dvou podkapitolách pak nastíním proces sběru a předzpracování dat a následně způsob jejich analýzy.

### **6.3.1. Metodologický přístup – dolování procesů**

Metoda dolování procesů (*process mining*) pochází původně z podnikatelské sféry. Jak ale bylo naznačeno v předchozí kapitole, začíná se tento metodologický přístup stále více využívat i v kontextu vzdělávání. Dolování procesů přitom označuje sadu metod, technik a nástrojů

zaměřujících se na extrakci informací a znalostí o zkoumaném procesu z tzv. logů, které jsou běžně ukládány v různých typech online informačních systémů včetně vzdělávacích systémů typu LMS (Pechenizkiy, Trčka, Vasilyeva, van der Aalst, & De Bra, 2009; Trčka, Pechenizkiy & van der Aalst, 2010; van der Aalst, 2016). Obecně může být metoda dolování procesů použita pro analýzu jakýchkoli dat, která mají charakter sekvence různých typů aktivit, jež pramení z opakovaného zapojování se různých aktérů do určitého procesu. Dolování procesů je tedy možné použít v takových případech, v nichž je možné určitou sekvenci aktivit či událostí chápat jakožto výsledek nějakého procesu s vnitřní strukturou (Reimann & Yacef, 2013). V případě této sondy je pak oním procesem vyplňování online testu studentem.

Využití metody dolování procesů obvykle slouží jednomu ze tří základních účelů: **objevení** (*discovery*), **potvrzení** (*conformance*) nebo **rozšíření** (*extension*) procesního modelu na základě analyzovaných procesních dat. V prvním případě neexistuje žádný předem známý či apriori model, a tudíž je cílem jeho konstrukce na základě dostupných dat. V druhém případě naopak existuje apriori model a cílem je ověřit, nakolik reálné procesy zaznamenané pomocí logovacího mechanismu určitého online systému skutečně odpovídají tomuto modelu. V případě rozšíření jde pak do určité míry o kombinaci obou předchozích přístupů. Sice existuje apriori model, ale cílem je ho rozšířit na základě dat o reálném průběhu zkoumaného procesu (srov. Pechenizkiy et al., 2009; Trčka, Pechenizkiy & van der Aalst, 2010). Využití metody dolování procesů v rámci této sondy spadá do první kategorie, jelikož jde o exploratorně pojatý výzkum a cílem je konstruovat model různých typů či způsobů chování studentů v průběhu vyplňování testů.

Využití metody dolování procesů obvykle realizováno ve třech základních krocích či fázích (srov. Trčka, Pechenizkiy & van der Aalst, 2010; van der Aalst, 2011, 2016). První fází je **předzpracování dat** (tzv. *pre-processing*), kdy je třeba upravit data do takové podoby, aby bylo možné aplikovat vybrané algoritmy pro dolování procesů. Nutnost předzpracování dat je dána především tím, že u většiny systémů nemají sbíraná data takovou podobu, která by bez dalších úprav odpovídala požadavkům konkrétního výzkumu.

Druhou fází je **identifikace a dolování procesního modelu** z analyzovaných dat. V tomto kroku se jednak využívají různé postupy pro exploraci a deskriptivní popis dat, jednak se aplikují vybrané algoritmy pro dolování procesů, jejichž výsledkem je pak určitá forma modelu. Jako příklad explorativních a deskriptivních technik lze zmínit vizualizaci variant procesů (tzv. *trace variants visualization*) či analýzu procesu za využití tečkového grafu (*dotted chart analysis*). Příkladem algoritmů pro dolování procesů pak může být např. *alpha algorithm* či *Heuristic Miner*. Výsledný model pak může mít podobu např. Petriho sítě (*Petri net*), kauzální sítě (*causal net*) či závislostního grafu (*dependency graph*).

Posledním krokem pak bývá **testování vytvořeného modelu**. Zde se používají různé postupy v závislosti na použitém algoritmu a formě modelu. V případě modelů v podobě Petriho sítě se obvykle provádí kontrola souladu modelu s analyzovanými daty (tzv. *conformance checking*), kdy se vyhodnocuje počet sekvencí, které jsou v souladu s modelem a které naopak modelu neodpovídají (Reimann & Yacef, 2013).

### 6.3.2. Analyzované případy

V této sondě byla analyzována data pocházející z celkem pěti online testů realizovaných v pěti různých kurzech v prostředí LMS Moodle provozovaném na FF MU. Všechny testy jsou součástí předmětů vyučovaných na FF MU, přičemž tematické zaměření těchto předmětů spadá do oblasti filozofie, kultury a historie. Výběr testů pro analýzu byl dán dvěma primárními kritérii:

1. Zahrnutí testů různých typů, a to jak z hlediska jejich nastavení v rámci LMS, tak i z hlediska toho, zda se jedná o testy formativní či sumativní.
2. Zahrnutí testů s co možná největším množstvím pokusů (resp. odpovědí) od studentů, jelikož velké množství pokusů dává větší šanci výskytu různých způsobů chování studentů při jejich plnění.

Základní charakteristiky analyzovaných testů jsou uvedeny v tabulce níže (viz tabulka 18). Testy A a B mají charakter spíše průběžných testů (tj. slouží pro účely formativního hodnocení), zatímco testy C, D a E jsou naopak koncipovány jako závěrečné (zápočtové) testy, a tudíž je možné je vnímat jako součást sumativního hodnocení. Ve všech těchto testech (tj. C, D a E) totiž studenti musí splnit test na určitou minimální úroveň, aby úspěšně ukončili studovaný předmět. Test C a test D pak mají podobu závěrečného testu v kurzech, které probíhají kompletně online, ostatní testy jsou součástí blended kurzů, které vedle online části obsahují také prezenční výuku. Test E jako jediný studenti vyplňují přímo v počítačové učebně na fakultě a pod dohledem vyučujícího, ostatní z analyzovaných testů jsou vyplňovány online.

Tabulka 18: Přehled základních charakteristik analyzovaných testů.

	Test A	Test B	Test C	Test D	Test E
<i>Typ testu</i>	průběžný	průběžný	závěrečný (zápočtový)	závěrečný (zápočtový)	závěrečný (zápočtový)
<i>Počet studentů</i>	14	66	311	176	43

Počet pokusů v testu	356	241	472	186	43
Počet otázek v testu	7	12	40	20	25
Časový limit	ano	ne	ano	ano	ano
Náhodný výběr otázek	mix	ano	ne	ano	ne
Počet možných pokusů	neomezeno	5	3	2	1
Požadováno splnění	ne	ne	ano	ano	ano
Stanovena minimální požadovaná známka	ne	ne*	ano	ano	ano
Zpětná vazba**	vše mimo správnou odpověď; vždy	vše mimo správnou odpověď; jen po dokončení pokusu	vše mimo správnou odpověď; dokud je test dostupný	jen body; vždy	vše; jen po dokončení pokusu
On-line/On-site	on-line	on-line	on-line	on-line	on-site

\* Přímo v testu není stanovena požadovaná známka, čili student nemusí v tomto testu získat určitou známku. Ovšem jde o jeden z průběžných testů, ze kterých musí student v průběhu kurzu jako celku získat určitý počet bodů.

\*\* V rámci LMS Moodle se při nastavování zpětné vazby u testů určuje jednak to, jaké informace se mají studentům zobrazit (např. body, správnost položky, správná odpověď apod.), jednak také v jaké fázi se jim mají dané informace zobrazit (např. jen ihned po dokončení pokusu či dokud je test studentům přístupný apod.).

### 6.3.3. Sběr a předzpracování dat

Pro sběr dat o chování studentů v průběhu vyplňování testů byl využit standardní logovací mechanismus (tzv. *logging system*) implementovaný v LMS Moodle (verze 3.1)<sup>126</sup>. Pro účely analýzy tak musela být data nejprve extrahována z databáze systému, konkrétně pak z tabulky *mdl\_logstore\_standard\_log*. Extrahována přitom byla data o veškeré aktivitě studentů

<sup>126</sup> Podrobné informace o fungování logovacího mechanismu lze nalézt v oficiální dokumentaci k systému na adrese [docs.moodle.org/31/en/Logging](https://docs.moodle.org/31/en/Logging).

v rámci systému Moodle v průběhu plnění vybraných testů. Data z tabulky *mdl\_logstore\_standard\_log* byla následně předzpracována pro účely analýzy. Po předzpracování dat obsahoval analyzovaný datový soubor následující proměnné:

- identifikátor testu (*qui.id*),
- identifikátor studenta (*student.id*),
- číslo pokusu v testu (*attempt.number*),
- název aktivity (*activity.name*),
- název skupiny aktivit (*activity.group*),
- zkratka skupiny aktivit (*activity.group.abbreviation*) a
- čas vytvoření záznamu (*timestamp*).

V průběhu předzpracování došlo především k vytvoření proměnné obsahující pojmenování zaznamenaných aktivit studentů a následně k vytvoření skupin aktivit stejného typu. Pojmenování aktivit vzniklo kombinací a úpravou proměnných používaných v rámci standardního logovacího mechanismu LMS Moodle a obsažených v datech před zpracováním. Základní výčet aktivit studenta v průběhu plnění online testů v LMS Moodle a způsob jejich pojmenovávání lze vidět v následující tabulce (viz tabulka 19). Jak je patrné, označení aktivity je kombinací jednak informace o provedené akci (*viewed*, *started*, *submitted*, *reviewed*), jednak informace o tom, čeho se provedená akce týká (*quiz*, *quiz\_attempt*, *attempt\_summary*).

Tabulka 19: Přehled základních názvů aktivit v průběhu plnění testu po předzpracování dat.

Názvy aktivit v testu	Zkratka	Význam
quiz_viewed	qv	Student si zobrazil úvodní stranu testu se základními informacemi a pokyny k jeho vyplňování.
quiz_attempt_started	qas	Student začal nový pokus v testu.
quiz_attempt_viewed	qav	Student si zobrazil stránku s otázkami testu. (Otázky v testu mohou být na jedné či více stránkách.)
attempt_summary_viewed	asv	Student se dostal na závěrečnou přehledovou stranu testu.
quiz_attempt_submitted	qasub	Student odeslal pokus v testu k vyhodnocení.
quiz_attempt_reviewed	qar	Student si zobrazil zpětnou vazbu k předchozímu pokusu v testu. (Tato možnost je dostupná jen v případě, že to vyučující u daného testu povolí.)



Obdobným způsobem jako záznamy v logovacím systému týkající se přímo aktivity v testech byly předzpracovány a pojmenovány záznamy související s jinými částmi kurzu a LMS jako celku. Zde bylo pouze nutné navíc rozlišit jiné testy dostupné v kurzu a test, který podléhal analýze. Důvodem bylo to, aby bylo možné odlišit aktivitu přímo v daném analyzovaném testu od případné aktivity v jiných testech v kurzu. Výše zmíněná aktivita *quiz\_viewed* tudíž znamená, že si student zobrazil úvodní stranu analyzovaného testu, kdežto aktivita *o.quiz\_viewed* značí zobrazení úvodní strany jiného testu v daném kurzu. Obdobně je pak zobrazení testu v úplně jiném kurzu označeno jako *oc.quiz\_viewed* (viz tabulka 20).

Související aktivity byly zároveň seskupovány do obecnějších kategorií, jak je naznačeno rovněž v tabulce 20. Seskupení se týkalo jednak plnění různých druhů aktivit studenta v kurzu (např. odevzdávání úkolu, přispívání do fóra, plnění jiných testů apod.), jednak zobrazování různých druhů studijních materiálů v kurzu (soubor, stránka, odkaz apod.).

Tabulka 20: Příklady názvů dalších aktivit (tj. aktivit mimo samotný test) po předzpracování dat.

<b>Příklady názvů dalších aktivit</b>	<b>Název skupiny aktivit</b>	<b>Zkratka</b>
course_viewed	course_viewed	cv
other_course_viewed	other_course_viewed	ocv
o.quiz_viewed	activity_viewed	av
oc.quiz_viewed	activity_viewed	av
page_viewed	material_viewed	mv
book_chapters_viewed	material_viewed	mv
resource_viewed	material_viewed	mv
user_viewed	user_info_viewed	uiv
user_grades_viewed	user_info_viewed	uiv
lesson_started	activity_performed	ap
questionnaire_submitted	activity_performed	ap
discussion_post_uploaded	activity_performed	ap
oc.quiz_attempt_viewed	activity_performed	ap

### 6.3.4. Analýza dat

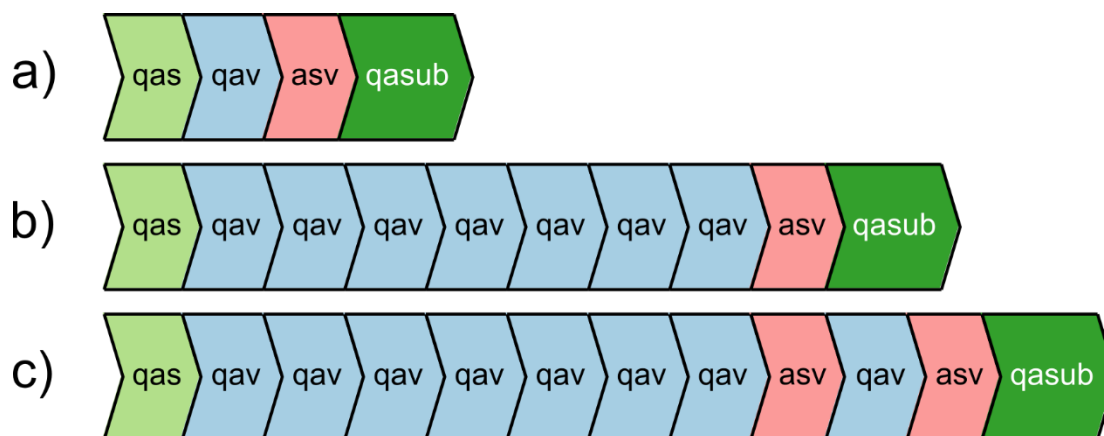
V rámci analýzy dat jsem v prvním kroku provedl exploraci variant procesů (*trace variants*), tj. případů, které obsahují stejné sekvence aktivit. Zde bylo základním cílem jednak zjistit, jaké varianty procesů se v analyzovaném datovém souboru vyskytují, jednak následně

hledat podobnosti mezi různými variantami procesů a seskupovat takové varianty procesů, které vykazují obdobné vzorce chování studentů při vyplňování testů. V druhém kroku pak bylo přistoupeno k tvorbě a analýze tzv. procesních map, k jejichž průzkumu byl využit nástroj *Disco* používající vlastní upravenou a rozšířenou implementaci algoritmu *Fuzzy Miner* (Günther & van der Aalst, 2007) zvanou *Disco miner*.

Důvodů pro využití právě procesních map spíše než jiných forem modelů bylo několik. Vzhledem k exploratornímu charakteru sondy šlo primárně o průzkum a pokud možno komplexní poznání reálného procesu spíše než o budování obecného modelu a jeho ověřování. Procesy zachycující reálné chování lidí přitom obvykle bývají méně strukturované, s čímž mívají „tradiční“ algoritmy (např. zmiňované *alpha algorithm* či *Heuristic Miner*) určité problémy a nedokážou tak poskytnout dostatečný vhled do charakteru analyzovaného procesu. Buď poskytnou příliš obecný model, který tudíž není schopen zachytit méně často se vyskytující formy chování, anebo naopak vyprodukují tzv. *spaghetti-like model*, který je příliš složitý, a tudíž jen obtížně srozumitelný a prakticky nepoužitelný (srov. Günther & van der Aalst, 2007; van der Aalst, 2016). Využití algoritmu *Fuzzy Miner* a modelů v podobě procesních map naopak dovoluje interaktivní úpravu úrovně abstrakce a následnou volbu odpovídajícího a přitom smysluplného popisu studovaného procesu.


## 6.4. Výsledky sondy C

Na obrázku 32 lze vidět příklady průchodů testem, které vykazují standardní chování studentů při plnění testů (*standard quiz-taking behavior*). Ve všech třech případech student postupuje tak, že nejprve spustí test (*qas*), poté vyplňuje úlohy v testu (*qav*) a následně si zobrazuje závěrečnou přehledovou stránku testu (*asv*), načte svůj pokus v testu odesílá k vyhodnocení (*qasub*). Varianta a) přitom ukazuje případ, kdy jsou všechny úlohy v testu na jedné stránce, kdežto varianty b) a c) pochází z testů obsahujících úlohy na více stránkách. Varianta c) pak zároveň znázorňuje případ, kdy se student ze závěrečné přehledové strany (*asv*) vrací zpět k vyplňování úloh (*qav*). To může být způsobeno např. tím, že si na závěrečné přehledové straně všiml nějaké opomenuté nezodpovězené úlohy, a tudíž se vrátil zpět k jejímu vyplnění. Je zároveň důležité zmínit, že v testu E se vyskytoval pouze tento typ chování studentů (tj. standardní vyplňování testu). Naopak ve všech ostatních analyzovaných testech se vyskytovaly i typy chování studentů, které lze označit za nestandardní vyplňování testu (*non-standard quiz-taking behavior*). Tento výsledek naznačuje, že v kontrolovaných podmínkách (tj. vyplňování testu přímo v počítačové učebně a pod dohledem vyučujícího) se studenti spíše neuchylují k nestandardnímu vyplňování testů, a naopak postupují tak, jak je očekáváno.



Obrázek 32: Příklad variant procesů vykazujících standardní typ chování studentů při vyplňování testů.

Obrázek 33 ilustruje způsob chování studentů při plnění online testů, který by bylo možné označit jako zneužití zpětné vazby (*feedback misuse*). Tento typ chování studentů lze charakterizovat tak, že si student v průběhu vyplňování testu zobrazí stránku s přehledem podrobné zpětné vazby k předchozímu pokusu v daném testu. Na této stránce se přitom zobrazují jednak odpovědi studenta z předchozího pokusu, jednak také informace o tom, zda byla uvedena odpověď správně či nikoli. Zároveň se může zobrazovat také doplňující zpětná vazba k jednotlivým úlohám či dokonce správná odpověď (v závislosti na nastavení testu a zpětné vazby učitelem). Tento typ chování studenta se tedy může vyskytovat jen v takových testech, které jsou využívány pro opakované vyplňování (tj. dovolují více pokusů v testu) a zároveň jsou nastaveny takovým způsobem, že studentům povolují zobrazování zpětné vazby k předchozím pokusům. V případě analyzovaných testů umožňují tento typ chování testy A a C, přičemž v obou testech se tento typ chování studentů vyskytl. Častěji se přitom objevoval v testu A.




Obrázek 33: Příklad variant procesů vykazujících chování typu zneužití zpětné vazby.

Další identifikovaný typ chování studentů v průběhu vyplňování testů lze označit jako zneužití studijních materiálů (*study materials misuse*). V případě zneužití studijních

materiálů (viz obrázek 34) student v průběhu plnění testu nahlíží do studijních materiálů obsažených v kurzu. Obvykle jde přitom o opakovanou činnost, kdy student postupně otevírá různé studijní materiály dostupné v kurzu. Lze tedy předpokládat, že se student v průběhu pokusu snaží dohledávat správné odpovědi na úlohy v testu. Zkratka *mv* zde přitom zahrnuje různé typy studijních materiálů, které se mohou v různých kurzech lišit.

V souvislosti s výše identifikovaným typem chování studentů (tj. zneužití zpětné vazby) lze přitom zmínit zajímavé zjištění, že ačkoli se oba typy chování mohou teoreticky vyskytovat v průběhu jediného pokusu, v analyzovaných testech se tyto typy chování v rámci jediného pokusu nikdy nevyskytovaly. To by mohlo naznačovat, že studenti spíše volí buď jednu, nebo druhou strategii nestandardního chování. Pro podporu této teze by však bylo třeba provést obdobnou analýzu na mnohem širším vzorku testů.




Obrázek 34: Příklad variant procesů vykazujících chování typu zneužití studijních materiálů.

Poslední detekovaný typ chování studentů při plnění testů by se dal označit jako *multitasking*. Toto označení je zvoleno proto, že se studenti v průběhu plnění hlavní aktivity (tj. plnění pokusu v daném testu) zároveň zapojují do jiných (vedlejších) aktivit, které s plněním testu přímo nesouvisí. Na obrázku 35 jsou znázorněny dva příklady takového chování, přičemž v obou případech bylo onou vedlejší aktivitou vyplňování jiného testu v kurzu.

Při podrobnějším průzkumu těchto variant přitom bylo možné odhalit, že se jedná o dvě různé situace. V první situaci (varianta a) student začne vyplňovat analyzovaný test (*qas*) a následně prohlíží studijní materiály (*mv*). Poté ovšem otevírá jiný test (*ap*) a začíná pokus v něm. Přičemž toto chování se opakuje ještě třikrát a až poté student ukončuje pokus v původním test (*qasub*). V průběhu plnění původního testu však student ve vedlejších testech pokusy pouze odstartoval, ale (prozatím) nedokončil. V druhém příkladu (varianta b)

naopak student odstartuje i dokončí pokusy ve dvou jiných testech, a teprve poté se vrací k hlavnímu test a ukončuje svůj pokus i zde.

Zajímavým zjištěním u tohoto typu chování bylo především to, že se nevyskytoval pouze u testu B. Test B je totiž oproti ostatním analyzovaným testům specifický v tom, že nemá nastaven pevný časový limit. Studenti jej tak mohou vyplňovat v průběhu delší doby. Nabízelo by se tedy vysvětlení, že někteří studenti v průběhu plnění tohoto testu mohou začít zároveň plnit jiné aktivity v kurzu a k dokončení testu se vrátit později. Za poměrně překvapivé lze však považovat to, že se tento typ chování objevil i v testu C, u něhož jde o závěrečný test s pevným časovým limitem a poměrně velkým množstvím otázek k zodpovězení.



Obrázek 35: Příklad variant procesů vykazujících chování typu multitasking.

Doplňme také, že mimo výše uvedené typy chování studentů v průběhu plnění testů bylo možné v datech nalézt i takové varianty procesů, které nezapadají do žádného z uvedených typů. Zároveň jde o případy, které lze jen obtížně interpretovat čistě na základě dat zaznamenávaných systémem (tj. na základě logů). Příkladem mohou být situace, kdy si student v průběhu vyplňování testu zobrazí hlavní stranu kurzu či hlavní stranu testu, ale již nepokračuje nikam dál (např. na nějaký studijní materiál či na stránku se zpětnou vazbou). Pro porozumění těmto zvláštním případům by tak zřejmě bylo třeba využít některou z kvalitativních výzkumných metod.

Zatímco výše byly představeny jednotlivé typy chování studentů v průběhu vyplňování testů (tj. *quiz-taking behavior*) na příkladech konkrétních variant procesů, obrázek 36 shrnuje všechny varianty procesů jednotlivých typů chování studentů v podobě tří procesních map<sup>127</sup>. Procesní mapy A a B zobrazují proces kompletně, u procesní mapy C jde o zjednodušený model, který vynechává některé méně významné cesty. U všech tří procesních map zároveň nejsou pro větší přehlednost zobrazeny tzv. *self-loops* (tj. případy, kdy vede cesta z aktivity určitého typu k aktivitě stejného typu – typicky např. postupné zodpovídání testových otázek na více stranách). U každé aktivity a cesty jsou pak zobrazeny frekvence

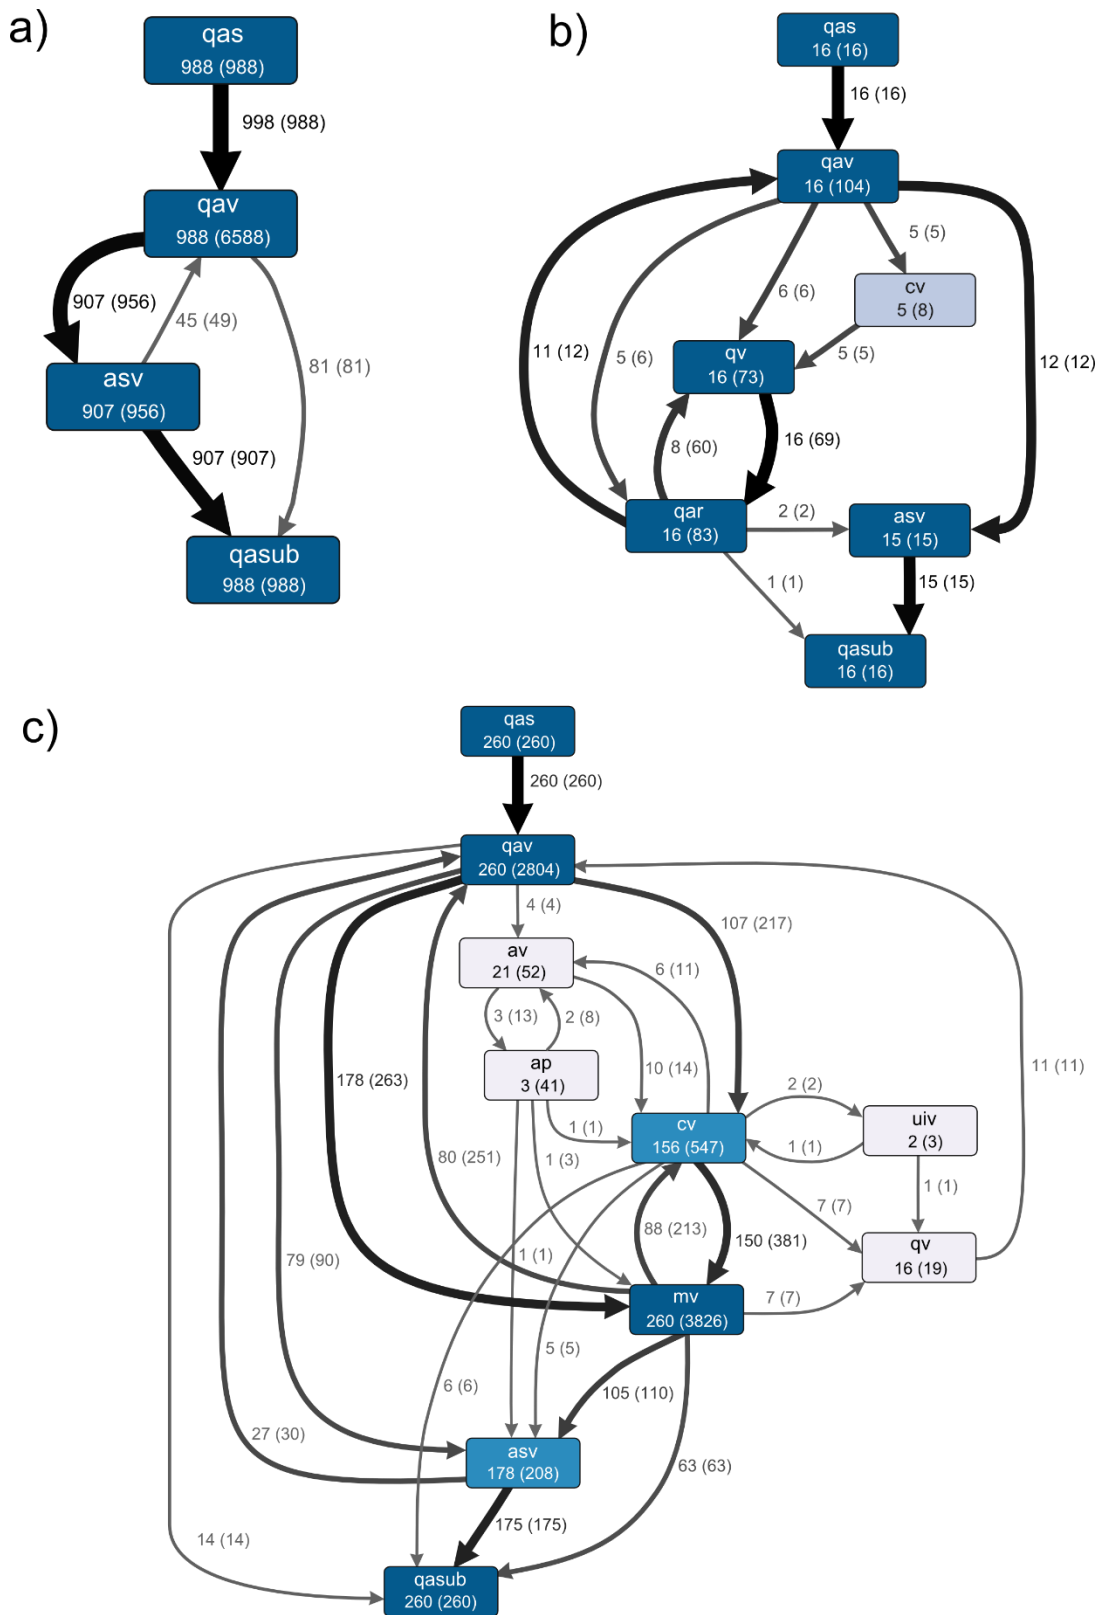
<sup>127</sup> Procesní mapa C zahrnuje jak chování typu zneužití studijních materiálů, tak i chování typu multitasking. Důvodem je to, že v analyzovaných datech se ve všech případech vyskytovalo chování typu multitasking společně s chováním typu zneužití studijních materiálů.

případů (*case frequency*) a následně v závorce absolutní frekvence (*absolute frequency*) výskytu dané aktivity či cesty.

Z uvedených procesních map lze zároveň vyčíst četnosti jednotlivých typů chování studentů při vyplňování testů. Z celkového počtu 1298 pokusů ve všech pěti analyzovaných testech se v 988 pokusech (tj. 76,12 %) vyskytovalo standardní chování studentů (*standard quiz-taking behavior*). Chování typu zneužití studijních materiálů (*study materials misuse*) se pak vyskytlo v celkem 260 pokusech (20,03 %) a jde tak o hlavní typ nestandardního chování studentů při plnění testů (*non-standard quiz-taking behavior*), který byl v analyzovaných datech z LMS Moodle odhalen. Zbývající dva typy nestandardního chování studentů v testech se pak vyskytovaly v mnohem menším počtu případů. Chování typu zneužití zpětné vazby (*feedback misuse*) se objevilo pouze v 16 pokusech (1,23 %) a chování typu *multitasking* se vyskytlo dokonce pouze ve třech pokusech (tj. 0,23 %). Celkově přitom bylo možné pomocí výše uvedených typů popsat 97,38 % všech analyzovaných případů.

Zároveň je vhodné zmínit, že jednotlivé procesní mapy dovoluují odhalovat i další zajímavé skutečnosti o chování studentů v průběhu vyplňování testů. Studenti např. poměrně často neodesílají test k vyhodnocení sami, nýbrž je jejich pokus odeslán k vyhodnocení automaticky poté, co vyprší stanovený časový limit pro vyplnění testu (v procesních mapách jde o všechny případy, kdy cesta na stránku *qasub* nevede přes stránku *asv*). To si lze vysvětlit buď tím, že studenti spoléhají na funkcionalitu systému, která pokus po vypršení časového limitu odešle automaticky (což ovšem nemusí platit vždy, jelikož je to dáno nastavením každého individuálního testu), anebo se do poslední chvíle snaží hledat odpověď např. ve studijních materiálech (viz 63 takových případů v procesní mapě C). Nezanedbatelná část studentů se pak ze závěrečné přehledové strany testu (*asv*) vrací zpět k vyplňování otázek (*qav*). To může být dáno nejen tím, že si student všiml opomenuté úlohy, nýbrž to může naznačovat i zapojení specifických strategií plnění testů (tzv. *quiz taking strategies*). Student může například nejprve rychle vyplnit úlohy, na které zná okamžitě odpověď, a teprve poté se postupně vracet k řešení obtížnějších úloh.

V neposlední řadě pak procesní mapy ukazují, že studenti poměrně běžně při vyplňování testů pracují s více okny/panely internetového prohlížeče. Je to patrné např. z procesní mapy C, kde v 178 případech pokračuje student ze strany s otázkami v testu (*qav*) přímo na stránku konkrétního studijního materiálu (*mv*), což je možné jen v případě, že má student v jednom okně/panelu spuštěný test, zatímco v druhém okně/panelu má zobrazenou např. hlavní stranu kurzu či stránku s přehledem studijních materiálů, ze které si pak již otevírá konkrétní studijní materiál.



Obrázek 36: Procesní mapy různých typů chování studentů při plnění testů:  
a) standardní chování, b) zneužití zpětné vazby, c) zneužití studijních materiálů spolu s typem multitasking.

## 6.5. Diskuze a závěr sondy C

Tato sonda využívala procesně orientovaný přístup k analýze dat o chování studentů v LMS Moodle při plnění online testů. V rámci tohoto přístupu přitom byla využita metoda dolování procesů, která umožňuje analýzu dat procesního charakteru. Přestože již existuje několik studií, které tuto metodu v kontextu vzdělávání využívají (např. Schoor & Bannert, 2012; Bannert, Reimann & Sonnenberg, 2014; Papamitsiou & Economides, 2016), či ji dokonce využívají přímo k analýze dat z LMS Moodle (Romero et al., 2016), obecně jsou procesně orientované přístupy a specificky metoda dolování procesů ve vzdělávání využívány spíše jen zřídka (srov. van der Aalst, Guo & Gorissen, 2013; Peña-Ayala, 2014b).

Doposud však neexistuje žádná studie, která by se věnovala aplikaci metod dolování procesů přímo v souvislosti s analýzou a detekcí různých forem chování studentů při plnění testů v rámci LMS Moodle. Primárním cílem této exploratorně pojaté sondy tak bylo prozkoumat možnosti dolování procesů jakožto metody analýzy k tomuto účelu. Zároveň sonda analyzovala data pocházející z testů různých typů a usilovala o odhalení různých způsobů chování studentů při vyplňování těchto testů. V následujících dvou podkapitolách nejprve shrnuji odpovědi na stanovené výzkumné otázky, a poté zmiňuji hlavní limity realizované sondy, jakož i možnosti dalšího výzkumu a důsledky zjištěných výsledků pro praxi.

### 6.5.1. Shrnutí odpovědí na stanovené výzkumné otázky

První výzkumná otázka se týkala obecně využitelnosti metody dolování procesů pro detekci specifických forem či způsobů chování studentů v průběhu plnění online testů v LMS Moodle. Přesněji pak bylo hlavním zájmem to, zda využití výhradně procesního přístupu k analýze dat o chování studentů umožní rozlišit různé typy či vzorce chování studentů při plnění testů. Čili zda je možné detekovat různé chování studentů při vyplňování testů jen za využití metod dolování procesů a dat procesního charakteru (logů) bez kombinace s dalšími analytickými postupy či typy dat (např. výše zmiňované přístupy založené na person-fit indexech a přístupy založené na rychlosti odpovídání). Výsledky sondy C přitom naznačují kladnou odpověď. S využitím metody dolování procesů bylo možné identifikovat čtyři různé typy chování studentů při plnění online testů. Zároveň bylo možné odlišit standardní chování studentů (*standard quiz-taking behavior*) od nestandardního chování (*non-standard quiz-taking behavior*) a v rámci nestandardního chování dále rozlišit tři různé typy. Lze tak souhlasit se závěry dosavadních studií (Papamitsiou & Economides, 2016; Romero et al., 2016), že využití metody dolování procesů k analýze dat o chování studentů v LMS může být přínosné zvláště



pro objevování, mapování a monitorování různých učebních procesů. Tento metodologický přístup se tak jeví být vhodným doplněním dosavadních analytických postupů a nástrojů.

Ve druhé výzkumné otázce byla zaměřena pozornost na to, jaké typy chování studentů v průběhu plnění online testů (tj. *quiz-taking behavior*) je možné s využitím metody dolování procesů odhalit. Jak bylo naznačeno v předchozím odstavci, celkem bylo možné v analyzovaných datech identifikovat a odlišit čtyři různé způsoby chování studentů při plnění testů. V prvním případě šlo o standardní chování, kdy studenti postupují dle očekávání, tzn.: spustí test, splní jednotlivé úlohy a odešlou své odpovědi k vyhodnocení. Ve zbývajících třech případech pak šlo o různé typy nestandardního testového chování. Konkrétně pak byly rozlišeny následující tři formy nestandardního chování studentů: a) chování typu zneužití zpětné vazby (*feedback misuse behavior*), při kterém studenti v průběhu plnění otázek v testu využívají zpětnou vazbu k předchozím pokusům v testu, b) chování typu zneužití studijních materiálů (*study materials misuse behavior*), u kterého studenti při vyplňování testů nahlíží do studijních materiálů dostupných v kurzu a c) chování typu multitasking (*multitasking behavior*), kdy se studenti při vyplňování testu zároveň zapojují do jiných výukových aktivit v rámci kurzu.

Zde lze přitom vidět určité paralely s existujícími výzkumy, zvláště pak s výzkumy realizovanými v kontextu inteligentních tutorských systémů (např. Baker, 2007; Baker et al., 2009; Baker, Goldstein, & Heffernan, 2011; Baker & Gowda, 2010; Muldner, Burleson, Van de Sande, & VanLehn, 2011). Příkladem může být odhalený typ chování označený jako zneužití zpětné vazby (*feedback misuse*), který lze do značné míry chápat jako odpovídající tomu, co je v kontextu systémů typu ITS označováno jako zneužívání nápovědy (*misusing help*) či obcházení systému (*gaming the system*).

Přesto je třeba zároveň upozornit na to, že výše identifikované typy chování nelze zcela ztotožnit s typy chování, které byly identifikovány v jiných studiích. Mimo jiné proto, že systémy typu ITS a systémy typu LMS jsou poměrně zásadně odlišné výukové technologie, které tudíž umožňují různé formy nestandardního chování studentů. Např. výše odhalený typ chování označený jako zneužití studijních materiálů lze zřejmě považovat za specifický právě pro systémy typu LMS. Navíc využití procesně orientovaného přístupu k detekci nestandardního chování studentů při plnění testů ve své podstatě sleduje velmi odlišnou rovinu či odlišný aspekt chování studenta než například častěji používané přístupy založené na délce odpovědi (*response time*). Lze tak do značné míry předpokládat, že využití takto výrazně odlišných přístupů bude zároveň odhalovat odlišné typy či způsoby chování studentů, a to i přesto, že se na první pohled mohou zdát podobné.

Poslední výzkumná otázka se pak týkala četnosti výskytu jednotlivých typů chování studentů při vyplňování online testů. V analyzovaných datech pocházejících z pěti testů různých typů se standardní testové chování vyskytovalo v cca 76 % všech případů (tj. pokusech studentů v testech), zatímco ve více jak pětině případů (cca 21,5 %) docházelo k výskytu nestandardní chování při plnění testů. V naprosté většině šlo přitom o nestandardní chování typu zneužití studijních materiálů (cca 20 %), kdežto ostatní typy nestandardní chování studentů se vyskytovaly jen zřídka. Zbývajících cca 2,5 % případů pak odpovídá takovému chování studentů, které zůstalo v rámci realizované sondy nevysvětleno.

Zároveň je však třeba zdůraznit, že z hlediska výskytu jednotlivých typů nestandardního chování studentů v testech se ukázal být zcela zásadním kontext. A to jednak co se týče typu testu a jeho „role“ v kurzu, jednak co se týče konkrétního způsobu nastavení testu v LMS, jakož i konkrétních podmínek, za jakých je test studenty vyplňován. Například výskyt chování typu zneužití zpětné vazby je možný jen v případě určitého nastavení testů. Bez odpovídajícího nastavení tak vůbec nemůže nastat. Zde se tudíž projevuje role učitele (či tvůrce kurzu), který vlastně zvoleným nastavením testu může určit, zda vůbec určitý typ nestandardního testového chování studentů bude možný. Jiným příkladem je analyzovaný test E, který byl studenty vyplňován tzv. *on-site*, tj. v počítačové učebně a pod dohledem vyučujícího. V tomto testu se totiž vyskytovalo pouze standardní chování studentů, což může naznačovat, že v tomto kontextu se studenti spíše neuchylují k nestandardnímu chování, přestože by třeba technicky (tj. z hlediska vlastností či nastavení systému) bylo možné. Zbývá dodat, že k obdobným závěrům o důležitosti vzdělávacího kontextu a zohlednění konkrétních podmínek kurzu či nastavení daného výukového nástroje dospívají také Agudo-Peregrina et al. (2014) či Gašević et al. (2016).

### **6.5.2. Limity sondy, možnosti dalšího výzkumu a důsledky pro praxi**

V souvislosti s limity sondy lze rozlišit na jedné straně limity dané pojetím a zaměřením sondy, na druhé straně pak limity dané podstatou a rozsahem analyzovaných dat. Především, v této sondě byla věnována pozornost výhradně mapování „pohybu“ studentů v LMS v průběhu plnění testu. Z toho automaticky plyne nutné omezení související s tím, jaké typy chování studentů je vůbec možné tímto přístupem detekovat. Zároveň je velmi pravděpodobné, že kombinací dolování procesů s dalšími technikami (např. shlukování) a zahrnutím dalších typů dat by bylo možné dosáhnout mnohem podrobnějšího a přesnějšího

vhledu do chování studentů v průběhu plnění testů.<sup>128</sup> Další výzkum je tak možné směřovat především ke kombinaci procesně orientovaného přístupu s dalšími používanými přístupy k detekci nestandardního chování studentů při plnění testů. Jinou možností rozšíření výsledků této sondy by bylo sledování rozdílů v chování u úspěšných a neúspěšných studentů (srov. Romero et al., 2016). Zajímavý směr dalšího výzkumu pak nabízí i van der Aalst, Guo a Gorissen (2013), kteří se věnují možnostem tzv. srovnávacího dolování procesů (*comparative process mining*).

Co se týče podstaty analyzovaných dat, je třeba zmínit, že logy ve skutečnosti nezaznamenávají reálné chování studentů v LMS ve své úplnosti, nýbrž vždy nutně zachycují pouze určitý fragment či výsek možného chování (srov. van der Aalst, 2016). A to jednak v závislosti na technickém řešení logovacího mechanismu v rámci daného systému (tj. ne všechno chování musí být zaznamenáváno), jednak také proto, že vždy pracujeme jen s určitým časovým úsekem. Nelze tak předpokládat, že by sonda zachytila všechny možné varianty procesů. Z hlediska rozsahu dat byl také analyzován jen omezený počet testů a jejich typů, takže je možné, že určité typy chování vůbec nebyly v datech zastoupeny, jelikož se vyskytují jen ve specifických podmínkách konkrétního způsobu využití či nastavení testu (podobně jako výše zmiňované zneužití zpětné vazby, které se může vyskytovat jen při určitém nastavení testu). Potenciál budoucích studií tak spočívá i v analýze výrazně většího množství dat z širšího spektra různých typů testů.

I přes uvedené limity lze výsledky sondy považovat za přínosné z hlediska praxe. Realizaci sondy lze totiž chápat jako určitou demonstraci toho, že dolování procesů lze využít k identifikaci (ne)standardního chování studentů při plnění testů, a to na základě dat, které v současnosti již LMS Moodle implicitně sbírá. Bylo by tak možné vytvořit analytický nástroj pro učitele, který by jim například v podobě vizualizace procesních map či variant procesů umožnil zjistit, zda studenti při plnění zadaného testu postupovali standardně či nikoli. To by pro učitele mohlo mít zásadní přidanou hodnotu zvláště u testů, které se podílejí na finálním hodnocení. Vizualizace v podobě procesních map má navíc oproti jiným způsobům vizualizace procesů tu výhodu, že je poměrně intuitivní a může tak být velmi dobře srozumitelná i pro učitele. Využití procesně orientovaného přístupu představeného v této studii, tak může v kontextu praktického využití sloužit jako první krok ke vzniku analytického nástroje poskytujícího učitelům lepší vhled do procesu vyplňování testů studenty.

---

<sup>128</sup> Např. pokud bychom navíc sledovali časový aspekt (tj. délku pokusu či přímo délku odpovídání na jednotlivé úlohy), tak lze očekávat, že u určitého množství případů, které jsou s využitím výhradně dolování procesů zařazeny do kategorie standardní chování, by bylo odhaleno chování typu hádání resp. tipování (tzv. *rapid-guessing behavior*).



## 7. Diskuze výsledků disertační práce

V diskuzních kapitolách v rámci jednotlivých sond jsem se zaměřoval primárně na shrnutí a diskuzi dílčích výzkumných otázek specifických pro každou z realizovaných sond. V této souhrnné diskuzní kapitole tak budu věnovat pozornost shrnutí a diskuzi výsledků disertační práce jako celku. Cílem kapitoly je podání odpovědi na hlavní výzkumnou otázku celé disertační práce, která zněla: *Jaké poznatky přináší využití metod analytiky učení a data miningu ve vzdělávání pro analýzu učení a výuky v systémech pro řízení výuky?* Zodpovězení této otázky přitom bude provedeno primárně skrze dílčí odpovědi na tři specifické výzkumné otázky disertační práce jako celku. Zároveň, aby došlo k naplnění jak meritorních, tak i metodologických cílů práce, budou při diskuzi specifických výzkumných otázek reflektovány věcné i metodologické aspekty každé z otázek.

**Sonda A** se zaměřovala na problematiku predikce úspěšnosti a pokládala si otázku: *Jaké jsou možnosti predikce úspěšného absolvování blended kurzů na základě temporálních aspektů návštěvnosti e-learningových opor kurzů v LMS?* Výsledky sondy přitom ukázaly, že v kontextu blended kurzů a za využití pouze temporálních aspektů návštěvnosti e-learningových opor v LMS jsou možnosti predikce úspěšnosti studentů značně omezené. V rámci sondy došlo k analýze dat týkajících se 2321 studentů studujících v 35 různých blended kurzech a byly testovány čtyři různé klasifikační algoritmy. Za účelem zjištění prediktivních schopností jednotlivých algoritmů bylo využito predikční testování externí validací, a to včetně zohlednění úrovně kurzů při rozdělování datového souboru na trénovací a testovací část. Výsledky predikčního testování přitom poukázaly na velmi malou schopnost algoritmů predikovat úspěšnost studentů napříč různými blended kurzy. U tří ze čtyř algoritmů byla dokonce predikční schopnost nižší než při využití tzv. baseline modelu, který pro všechny studenty predikuje stejný výsledek (tj. úspěšnost v kurzu). Pro jakoukoli praktickou aplikaci by tudíž takové klasifikační algoritmy resp. modely byly zcela nepoužitelné.

Výsledky sondy tak vrhají poněkud nové světlo na současné možnosti predikce úspěšnosti studentů v kontextu blended kurzů. Přestože je problematika predikce úspěšnosti (příp. identifikace rizikových studentů) jednou z relativně silně zastoupených oblastí analytiky učení i data miningu ve vzdělávání (srov. Dawson et al., 2014; Gašević et al., 2016; Romero & Ventura, 2013), v případě blended kurzů, které jsou však v kontextu univerzitní výuky naprosto dominantní formou (Švaříček & Zounek, 2008), je třeba výsledky dosavadních výzkumů posuzovat s velkou obezřetností. Většina doposud publikovaných studií se totiž zaměřuje na data z jediného kurzu, případně pak jen z několika málo kurzů. A to i přesto, že

již nějakou dobu existují obavy z příliš velké variability napříč různými kurzy, a tudíž z nemožnosti považovat zjištěné výsledky za platné a navrhované modely za použitelné nad rámec kurzů analyzovaných v daných studiích (srov. Gašević, Dawson, & Siemens, 2015; Gašević et al., 2016; Joksimović et al., 2015). Zřejmě hlavním přínosem sondy je tak díky analýze dat 35 různých kurzů především to, že potvrzuje výše naznačené obavy některých výzkumníků. Nezbyvá tak, než opětovně spolu s Gaševićem, Dawsonem a Siemensem (2015) apelovat na to, aby autoři budoucích výzkumů a studií využívali data z co možná nejširšího spektra různých kurzů. Jedině tak totiž bude možné získat přesnější představu o tom, nakolik jsou zjištěné výsledky a použité prediktivní postupy skutečně zobecnitelné a v praxi použitelné.

Co zatím v dosavadních studiích nebylo akcentováno vesměs vůbec, a co tudíž může být považováno za další z důležitých přínosů realizované sondy, jsou otázky týkající se používaných prediktorů v souvislosti s aplikovanými prediktivními metodami. Výsledky sondy totiž ukázaly, že při využití různých klasifikačních algoritmů se mohou jevit jako důležité odlišné prediktory. Tento fakt přitom v dosavadních studiích zatím nebyl řešen, nýbrž byla věnována pozornost pouze úspěšnosti resp. správnosti predikce (srov. Romero, Espejo, Zafra, et al., 2013; Romero, López, Luna, et al., 2013; Sheshadri et al., 2018; Zafra et al., 2011). Přitom jde o věcně zcela zásadní záležitost, jelikož to výrazně komplikuje otázku po tom, které faktory související s výukou a učením v blended kurzech jsou relevantní z hlediska predikce úspěšnosti studentů. Nutno však zároveň upozornit na možnost, že zde opět hraje roli příliš velká variabilita napříč různými kurzy či obecně velké množství šumu v analyzovaných datech. Je tudíž možné, že preference různých prediktorů napříč jednotlivými klasifikačními algoritmy souvisí (alespoň částečně) s jejich neschopností přijít s dostatečně funkčním obecným modelem. A kdyby naopak dané klasifikačními algoritmy byly schopné přijít s dostatečně přesným modelem, rozdíly v preferenci jednotlivých prediktorů by mohly být výrazně menší.

V **sondě B** byla věnována pozornost interakci v online diskuzních fórech a využití analýzy sociálních sítí. Sonda si tak kladla otázku: *Jak je využitelná metoda analýzy sociálních sítí pro účely zkoumání a rozlišování různých forem interakce studentů a učitelů v online diskuzních fórech v LMS?* Na základě výsledků sondy, která analyzovala data o interakci studentů a učitelů v diskuzních fórech napříč 453 kurzy, lze říci, že analýza sociálních sítí poskytuje účinný nástroj pro studium komunikace a interakce v online diskuzních fórech v LMS. V tomto ohledu jsou tedy výsledky sondy v souladu s dosavadními výzkumy stavějícími na analýze sociálních sítí, které naznačovaly značný potenciál této výzkumné metody (srov. např. Brooks, Greer, & Gutwin, 2014; Ghadirian, Salehi, & Ayub, 2018;

Joksimović et al., 2016; Tirado-Morueta, Maraver-López, & Hernando-Gómez, 2017; Wise & Cui, 2018; Zhang, Skryabin, & Song, 2016). V realizované sondě se za využití analýzy sociálních sítí podařilo odhalit čtyři obecné formy interakce v diskuzních fórech, které lze při podrobnějším pohledu dále členit na dílčí specifické podtypy. Porovnání jednotlivých forem interakce za využití vybraných ukazatelů míry zapojení do diskuze ve fóru a za využití základních SNA metrik popisujících síť interakce jako takovou přitom ukázalo na zásadní rozdíly mezi jednotlivými nalezenými typy interakce. To lze vnímat jako doplňující podporu pro navrženou typologii a interpretaci jednotlivých typů.

Z věcného hlediska lze za největší přínos realizované sondy považovat to, že nabídla podrobnější vhled do způsobů, jakými jsou v rámci blended kurzů v kontextu univerzitní výuky využívány online diskuzní fóra a interakce v nich. Stejně tak sonda poskytla lepší představu o tom, nakolik jsou vůbec online diskuzní fóra jakožto jeden ze stěžejních výukových nástrojů v systémech typu LMS využívána. Obecné posouzení četnosti využívání diskuzních fór nás přitom může vést k závěru, že nejde o příliš často využívaný výukový nástroj. Zvláště pak, pokud nás zajímá primárně takové využití, ve kterém dochází k intenzivní komunikaci a interakci mezi studenty a učiteli i mezi studenty navzájem. Co je však důležitější, v souvislosti s interakcí v online diskuzních fórech lze odhalit strukturně zcela odlišné formy interakce studentů a učitelů. To naznačuje, že vyučující používají ve svých kurzech diskuzní fóra velmi různorodými způsoby, které se liší nejen v míře zapojení jednotlivých studentů (ale i samotných vyučujících), nýbrž především ve způsobu jejich zapojení.

V analyzovaných datech je tak možné nalézt kurzy tvořící malou skupinu intenzivně komunikujících účastníků, stejně jako větší kurzy, kde lze rozlišit studenty tvořící jádro diskuzní skupiny a naopak ty, kteří se zapojují jen okrajově. Stejně tak byly identifikovány kurzy stavějící na interakci v menších skupinkách studentů či naopak kurzy, kde probíhá interakce mezi studenty navzájem jen velmi ojediněle, jelikož v online fórech probíhá primárně individuální komunikace mezi vyučujícím a jednotlivými studenty. Využití analýzy sociálních sítí se v tomto kontextu zdá být zcela zásadní a možná dokonce i nenahraditelné, což potvrzuje názory některých z autorů (Wise & Paulus, 2016), že je nutné stavět na využití pokročilejších a sofistikovanějších metod než jednoduché sumativní míry interakce jako např. počet vložených příspěvků. Bez možnosti analyzovat nejen samotné aktéry diskuze či počty jejich diskuzních příspěvků, ale také vztahy mezi nimi a interakční síť jako celek, by vůbec nebylo možné odhalit tyto strukturně odlišné formy interakce. Dva různé kurzy totiž mohou obsahovat stejné množství diskuzních fór, stejné množství diskuzních příspěvků a stejné množství účastníků diskuze, a přitom vykazovat zcela odlišné typy interakce.

Významný přínos sondy B pak vnímám i v tom, že poukázala na několik různých směrů, kam by bylo možné při výzkumu interakce v online diskuzních fórech napřít další výzkumné úsilí. Zvláštní zmínku si v tomto ohledu zaslouží především tři oblasti: Výzkum dynamických aspektů interakce v online diskuzních fórech, kterému doposud nebylo věnováno příliš pozornosti (viz Zhang, Skryabin, & Song, 2016). Zaměření pozornosti na „pasivní“ zapojení studentů, které může být v kontextu učení prostřednictvím online diskuzních fór rovněž velmi důležité, přestože je obtížněji zachytitelné (viz Wise, Hausknecht, & Zhao, 2014). V neposlední řadě se pak zdá plodné využít při výzkumu interakce v online diskuzních fórech kombinaci více výzkumných metod či přístupů. Značný potenciál přitom spatřuji především v kombinaci analýzy sociální sítě s obsahovou analýzou či některými přístupy z oblasti kvalitativní analýzy dat (srov. Haythornthwaite, de Laat, & Schreurs, 2016; Heo, Lim, & Kim, 2010; Wise & Paulus, 2016)

V poslední **sondě C** jsem se zaměřil na proces vyplňování online testů studenty. Pro analýzu tohoto procesu jsem pak použil metodu označovanou jako dolování procesů. Hlavní otázka této sondy přitom zněla: *Jak je využitelná metoda dolování procesů pro účely detekování specifických způsobů chování studentů v průběhu plnění online testů v LMS?* Podobně jako v případě sondy B lze na základě výsledků této sondy konstatovat užitečnost takového analytického postupu, neboť využití dolování procesů pro analýzu chování studentů v průběhu plnění online testů se ukázalo jako účinné. Při analýze 1298 pokusů od 610 studentů v pěti testech různých typů se za využití dolování procesů podařilo odhalit čtyři základní formy chování studentů v průběhu plnění online testů v LMS. Sonda přitom byla jedním z vůbec prvních výzkumů, které se zaměřily na využití dolování procesů přímo v souvislosti s chováním studentů při vyplňování online testů (srov. Papamitsiou & Economides, 2016). Už jen v tomto ohledu lze tudíž spatřovat jeden z důležitých přínosů realizované sondy.

Věcné výsledky sondy ukázaly, že při analýze procesu vyplňování online testu je možné vedle standardního chování studentů odhalit také tři různé formy nestandardního chování. Mezi tyto formy patří zneužití studijních materiálů, zneužití zpětné vazby a chování typu multitasking. A přestože lze vidět určité paralely s výzkumem zaměřujícím se na systémy typu ITS, v rámci kterého dochází k identifikaci obdobných forem chování označovaných jako zneužívání nápovědy či obcházení systému, formy nestandardního chování identifikované v této sondě lze považovat do značené míry za unikátní. Vychází totiž jednak z procesně orientované analýzy, jednak z prostředí kurzů v systému typu LMS. Zároveň je však nutné zmínit důležitý limit, kterým je množství analyzovaných testů. Bylo by proto nanejvýš vhodné ověřit výsledky realizované sondy na výrazně větším počtu testů. Mimo větší množství



analyzovaných dat se však zdá, že oproti sondě B a v ní využití analýze sociálních sítí nenabízí samotná metoda dolování procesů až tak široké možnosti pro rozšiřující či navazující výzkum (mluvíme-li tedy specificky o využití dolování procesů v souvislosti s procesem vyplňování online testů studenty). Výrazný prostor pro další výzkum a zároveň případné praktické uplatnění se však otevírá při kombinaci dolování procesů s dalšími metodami a postupy pro identifikaci a detekci různých forem chování studentů při plnění testů.

Oproti analýze sociálních sítí využití v sondě B se pak také velmi silně nabízí využití metody dolování procesů v kontextu jiných typů výukových aktivit realizovaných v prostředí LMS. V tomto ohledu lze v souvislosti s dolováním procesů hovořit o zřejmě výrazně větších možnostech využití než v souvislosti s analýzou sociálních sítí. Přeci jen, ne všechny typy výukových aktivit v LMS obsahují nějakou interakci mezi studenty a učiteli či studenty navzájem, případně negenerují taková data, která by dávalo smysl analyzovat a interpretovat za využití analýzy sociálních sítí. Na druhou stranu většina aktivit studentů v LMS zřejmě bude mít ze své podstaty procesní charakter či alespoň bude interpretovatelná jako nějaká forma procesu. Tudíž se otevírá obrovský prostor pro využití metody dolování procesů pro analýzu chování uživatelů (a to nejen studentů, ale i učitelů) v rámci dalších typů výukových aktivit probíhajících v systémech pro řízení výuky.

V souvislosti s hlavní výzkumnou otázkou jako takovou, tj. jaké poznatky přináší využití metod analytiky učení a data miningu ve vzdělávání pro analýzu učení a výuky v systémech pro řízení výuky, lze pak doplnit či spíše zdůraznit několik obecných zjištění plynoucích s realizovaného disertačního projektu. Z věcného hlediska se odvážím tvrdit, že využití metod analytiky učení a data miningu ve vzdělávání přináší zcela zásadní poznatky týkající se průběhu učení a výuky v online systémech typu LMS. Zároveň jde často o poznatky nové a netušené. Příkladem z této disertační práce mohou být doposud nepopsané formy interakce v online diskuzních fórech, které odhalila sonda B, či chování typu multitasking v rámci plnění online testů, jež by bylo možné předem očekávat jen stěží. Zdá se tak, že tyto nové analytické metody a přístupy skutečně dokáží otevřít onu černou skříňku zmiňovanou v úvodu a poskytnout tak výzkumníkům nový vhled do dění v kurzech probíhajících v LMS. Zásadní je přitom to, že metody analytiky učení a data miningu ve vzdělávání otevírají prostor, který doposud zůstával ne-li zcela, pak přinejmenším ve značné míře, nedostupný. Zatímco využití „tradičních“ výzkumných metod v tomto kontextu doposud přinášelo obvykle jen zprostředkovanou informaci, nyní se objevuje možnost téměř přímého sledování dění v kurzu. Pokud bych využil přípodobnění k tradiční výuce ve školní třídě, pak jde asi o takovou situaci, jako by se nám nyní otevřela možnost nejen se žáků či učitele na průběh výuky ptát, nýbrž v dané třídě přímo být (resp. tam mít kameru) a sledovat, co přesně se v průběhu výuky

děje. Množství nových poznatků, které mohou být tímto novým přístupem odhaleny, je tudíž obrovské.

Co se týče metodologického hlediska, jsem přesvědčen, že hlavní potenciál metod z oblasti analytiky učení a data miningu ve vzdělávání pro výzkum učení v online prostředí tkví prozatím stále spíše v exploratorně pojatých přístupech. Realizované sondy, jak věřím, do značné míry potvrdily předpoklad identifikovaný i v rámci přehledové kapitoly, že je vhodné nadále pokračovat především v exploratorně pojatém výzkumu. To ostatně souvisí s výše uvedeným. Jestliže se nám teprve v nedávné době otevřel zcela nový prostor pro výzkum učení v online prostředí, je třeba tento prostor nejprve alespoň v základu zmapovat, než bude možné pustit se do budování obecnějších teorií a jejich následného ověřování. Současně se však ukázalo být velmi důležitým i to, aby tento exploratorně pojatý výzkum dostatečně zohledňoval komplexitu a variabilitu fenoménu učení v online prostředí. Vezmeme-li jako příklad učení prostřednictvím online kurzů v LMS, pak se zdá nezbytné, aby další výzkum reflektoval odlišnosti mezi jednotlivými kurzy a usiloval tak o analýzu dat z co možná nejširšího spektra různých kurzů. Bez toho totiž nebude možné získat ucelenou představu o různých způsobech, jakými může docházet k učení a výuce prostřednictvím LMS, a tudíž nebude možné se přesunout k budování smysluplných obecných teorií a následnému konfirmačně orientovanému výzkumu.

## Závěr

Vzhledem k tomu, že k zodpovězení položených výzkumných otázek a naplnění stanovených cílů práce došlo v předchozí diskuzní kapitole a na konkrétnější úrovni v rámci diskuzních kapitol jednotlivých realizovaných sond, dovoluji si v úplném závěru přesunout pozornost na poněkud obecnější úroveň. Text disertační práce jsem v samotném úvodu začal citátem Sherlocka Holmese o tom, že je chybou teoretizovat před tím, než máme k dispozici data. Tento citát, jak věřím, čtenáře přinejmenším zarazil. Je totiž v rozporu s tradičním modelem empirické vědy, který naopak teorií začíná. Z ní jsou následně vyvozeny hypotézy, které jsou na základě získaných dat ověřovány. Resp. spíše zamítány, budeme-li souhlasit s Popperem (1997) v tom, že se tento proces řídí spíše metodou falzifikace než verifikace. Sherlockovo přesvědčení o primátu dat před teorií přitom nebylo zmíněno samoúčelně. Jsem totiž přesvědčen, že oblast data miningu ve vzdělávání a analytiku učení má do značné míry podobná východiska jako Sherlock Holmes. Nabízí se tudíž otázka po tom, jaký je vlastně vztah těchto nově se formujících výzkumných oblastí k tradiční a etablované metodě empirického výzkumu.

Na určitý souboj dvou kultur či paradigmat v kvantitativním výzkumu jsem poukazoval již v první kapitole v souvislosti s data science a exploratorní analýzou dat. Např. Hayashi (1998) přitom skutečně hovořil o tom, že oblast data science je třeba vnímat jako odlišnou od dosavadních tradičních a etablovaných metod výzkumu. Ocumpaughová et al. (2014) pak přímo říkají, že unikátním aspektem analytiku učení a data miningu ve vzdělávání oproti tradičním výzkumným metodám je to, že nevyžadují předem zformulované hypotézy. To je autory vnímáno jako užitečná vlastnost, jelikož to snižuje riziko konfirmačního zkreslení (*confirmation bias*), ke kterému dle autorů může docházet v tradičním modelu empirické vědy, kdy dochází k testování pouze vybraných hypotéz vycházejících z určitého teoretického rámce.

Roli teorie v data miningu ve vzdělávání a v analytice učení však různí autoři nahlíží z různých úhlů. Například je zde celé číslo časopisu *Journal of Learning Analytics*, které se věnuje právě postavení teorie v rámci analytiku učení (viz Dawson, Mirriahi, & Gašević, 2015). Wiseová a Shaffer (2015) přitom v tomto čísle prezentují poměrně jasné stanovisko, že s rozvojem analytiku učení a dostupností velkých objemů dat hraje ve skutečnosti teorie ve výzkumu a realizovaných analýzách ještě důležitější roli než kdy dříve. Podobně Gašević et al. (2016) považují právě nedostatečné zohlednění teorie za jednu ze slabin dosavadního výzkumu v oblasti analytiku učení.

Zdá se tak, že i v samotných oblastech analytiky učení a data miningu ve vzdělávání dochází k určitému souboji paradigmat a vyjasňování toho, jaké je postavení teorie v procesu výzkumu v rámci obou oblastí, a jak se tudíž obě oblasti vzdalují či naopak blíží tradiční vědecké metodě. Po několika letech strávených podrobným studiem těchto oblastí se domnívám, že z metodologického hlediska mají výzkumy v oblasti data miningu ve vzdělávání a analytiky učení skutečně poněkud jiný charakter, než výzkumy vycházející z tradičního modelu empirické vědy. Zároveň jsem však přesvědčen, že to není dáno ani tak tím, že by analytika učení a data mining ve vzdělávání byly v rozporu se zavedenou vědeckou metodou, nýbrž tím, že se v řadě výzkumných témat pohybujeme do značné míry v předteoretické či v Kuhnově (2008) pojetí předparadigmatické fázi. I z toho důvodu jsem proto přesvědčen o oprávněnosti výše zmiňovaného apelu na exploratorně pojatý výzkum. Jsme-li totiž stále v předteoretické fázi, jsou to právě především výsledky podrobné explorační, které mohou být využity pro formulaci teorií a hypotéz.

Data mining ve vzdělávání a analytika učení jakožto výzkumné směry vycházející z myšlenek exploratorní analýzy dat (Tukey, 1962, 1977) se přitom právě v této předteoretické fázi zdají být nebyvale silné. Dovolují zkoumat fenomény, které byly doposud jen obtížně přístupné, a umožňují objevovat jevy, které nejsou jednoduše předvídatelné na základě dosavadních výzkumů a teorií. Dle Berlanda, Bakera a Bliksteina (2014) navíc přímo vybízí ke kombinaci s kvalitativně orientovanými výzkumnými metodami, což jejich explorační potenciál dále umocňuje. Jsem tudíž přesvědčen, že právě v tomto ohledu lze spatřovat největší přínos analytiky učení a data miningu ve vzdělávání, a to nejen pro oblast e-learningu a výzkum učení v online prostředí, nýbrž i pro pedagogiku a pedagogický výzkum jako takový.

## Seznam zkratk

AA	Academic Analytics (akademická analytika)
AES	Automated Essay Scoring (automatizované hodnocení písemných prací)
AI	Artificial Intelligence (umělá inteligence)
ALS	Adaptive Learning System (adaptivní výukový systém)
CAT	Computerized Adaptive Testing (počítačové adaptivní testování)
CBA	Computer-Based Assessment (počítačové hodnocení)
CBE	Computer-Based Education (na počítačích založené vzdělávání)
CBT	Computer-Based Testing (počítačové testování)
CMS	Course Management System (systém pro správu kurzu)
CSCL	Computer-Supported Collaborative Learning (počítačem podporované kolaborativní učení)
EDM	Educational Data Mining (data mining ve vzdělávání)
EWS	Early Warning System (systém včasného varování)
ICT	Information and Communication Technologies (informační a komunikační technologie)
ILT	Integrative Learning Technologies (integrativní vzdělávací technologie)
IRT	Item Response Theory (teorie odpovědi na položku)
ITS	Intelligent Tutoring System (inteligentní tutorský systém)
LA	Learning Analytics (analytika učení)
LMS	Learning Management System (systém pro řízení výuky)
ML	Machine Learning (strojové učení)
MLA	Multimodal Learning Analytics (multimodální analytika učení)
MLE	Managed Learning Environment (řízené vzdělávací prostředí)
MOOC	Massive Open Online Courses (masové otevřené online kurzy)
MU	Masarykova univerzita
MUVE	Multi-User Virtual Environment (multi-uživatelské virtuální prostředí)
NLP	Natural Language Processing (zpracování přirozeného jazyka)

OLE	Online Learning Environment či Open Learning Environments (online vzdělávací prostředí či otevřené vzdělávací prostředí)
RS	Recommender System (doporučovací systém)
SQL	Structured Query Language (strukturovaný dotazovací jazyk)
SIS	Student Information System (studentský informační systém)
SLA	Social Learning Analytics (sociální analytika učení)
SNA	Social Network Analysis (analýza sociálních sítí)
SPOC	Small Private Online Courses (malé uzavřené online kurzy)
SRL	Self-Regulated Learning (seberegulované učení)
VLE	Virtual Learning Environment (virtuální vzdělávací prostředí)
VW	Virtual Worlds (virtuální světy)

## Seznam obrázků

Obrázek 1: Základní vymezení oblasti data miningu ve vzdělávání a analytiku učení (dle Romero & Ventura, 2013).-----	20 -
Obrázek 2: Návrh výchozího vymezení data miningu ve vzdělávání a analytiku učení včetně základního vytyčení oblasti, na kterou se zaměřuje tato disertační práce (šrafovaná oblast).-----	22 -
Obrázek 3: Schéma naznačující vztah mezi pojmy <i>online learning</i> , <i>blended learning</i> , <i>off-line learning</i> a <i>e-learning</i> (dle Mason & Rennie, 2006, s. 14).-----	29 -
Obrázek 4: Schéma naznačující vztah mezi ILT, LMS a jednotlivými kategoriemi nástrojů tvořících LMS (dle Kitsantas & Dabbagh, 2010, s. 24).-----	33 -
Obrázek 5: Počty nalezených výsledků v rámci Google Scholar zmiňujících pojem data science dle jednotlivých let. Výskyt hledaného termínu „data science“ je omezen na název dokumentu.-----	37 -
Obrázek 6: Vymezení oblasti data science jakožto průniku informatiky, statistiky a doménových znalostí.-----	44 -
Obrázek 7: Konceptualizace procesu aplikace data miningu ve vzdělávání jakožto formativní evaluační techniky (podle Romero, Ventura, Pechenizkiy, & Baker, 2010).-----	65 -
Obrázek 8: Konceptualizace procesu aplikace data miningu ve vzdělávání inspirovaná obecným procesem dobývání znalostí z databází (podle Bousbia & Belamri, 2014).-----	67 -
Obrázek 9: Různé úrovně granularity a množství dat (podle Romero & Ventura, 2013).-----	73 -
Obrázek 10: Obecný rámec zahrnující šest základních dimenzí analytiku učení (podle Greller & Drachsler, 2012).-----	88 -
Obrázek 11: Počty nalezených výsledků v rámci Google Scholar zmiňujících analytiku učení a data mining ve vzdělávání dle jednotlivých let. Výskyt hledaného termínu „learning analytics“ resp. „educational data mining“ není omezen (tj. může se objevit kdekoli v dokumentu).-----	92 -
Obrázek 12: Počty nalezených výsledků v rámci Google Scholar zmiňujících analytiku učení a data mining ve vzdělávání dle jednotlivých let. Výskyt	

hledaného termínu „learning analytics“ resp. „educational data mining“ je omezen pouze na název dokumentu. -----	93 -
Obrázek 13: Schéma naznačující výzkumný design disertační práce. -----	135 -
Obrázek 14: Konceptualizace časových intervalů mezi jednotlivými návštěvami kurzu (dle Jo, Kim, & Yoon, 2015). -----	162 -
Obrázek 15: Křivka ROC při použití logistické regrese jako klasifikačního algoritmu a kompletních dat pro účely tréninku (vlevo) včetně vyznačeného cut-off skóre (vpravo). -----	167 -
Obrázek 16: Vytvořený rozhodovací strom při použití kompletních dat. -----	169 -
Obrázek 17: Křivka ROC při použití rozhodovacího stromu jako klasifikačního algoritmu a kompletních dat pro účely trénování algoritmu. -----	170 -
Obrázek 18: Křivka ROC při použití náhodného lesu jako klasifikačního algoritmu a kompletních dat pro účely trénování. -----	171 -
Obrázek 19: Křivka ROC při použití podpůrných vektorů jako klasifikačního algoritmu a kompletních dat pro účely trénování algoritmu. -----	172 -
Obrázek 20: Příklad interakce typu A – žádná interakce. -----	202 -
Obrázek 21: Příklad interakce typu B1 – málo participantů. -----	203 -
Obrázek 22: Příklad interakce typu B2 – hodně participantů, málo interakce. -----	204 -
Obrázek 23: Příklad interakce typu B3 – interakce typu „had“. -----	205 -
Obrázek 24: Příklad interakce typu C1 – od studentů k učitelům. -----	206 -
Obrázek 25: Příklad interakce typu C2 – od učitele ke studentům. -----	207 -
Obrázek 26: Příklad interakce typu C3 – interakce oběma směry. -----	208 -
Obrázek 27: Příklad interakce typu C4 – dva učitelé ve středu. -----	209 -
Obrázek 28: Příklad interakce typu D1 – interakce ve velké skupině se silným středem. -----	210 -
Obrázek 29: Příklad interakce typu D2 – intenzivní interakce v malé skupině. -----	212 -
Obrázek 30: Příklad interakce typu D3 – rovnoměrná interakce ve velké skupině. -----	213 -
Obrázek 31: Příklad interakce typu D4 – skupinová interakce. -----	214 -



Obrázek 32: Příklad variant procesů vykazujících standardní typ chování studentů při vyplňování testů. -----	243 -
Obrázek 33: Příklad variant procesů vykazujících chování typu zneužití zpětné vazby. -----	243 -
Obrázek 34: Příklad variant procesů vykazujících chování typu zneužití studijních materiálů. -----	244 -
Obrázek 35: Příklad variant procesů vykazujících chování typu multitasking. -----	245 -
Obrázek 36: Procesní mapy různých typů chování studentů při plnění testů: a) standardní chování, b) zneužití zpětné vazby, c) zneužití studijních materiálů spolu s typem multitasking. -----	247 -



## Seznam tabulek

Tabulka 1: Přehled základních odborných knih věnujících se specificky problematice data miningu ve vzdělávání či analytice učení. -----	- 52 -
Tabulka 2: Vybraná speciální čísla odborných časopisů zaměřujících se na analytiku učení. -----	- 54 -
Tabulka 3: Srovnání různých konceptualizací procesu analytiky učení. -----	- 86 -
Tabulka 4: Přehled vybraných analytických nástrojů a systémů a jejich stručný popis. -----	- 97 -
Tabulka 5: Přehled kritérií pro volbu tematického zaměření realizovaných výzkumných sond. -----	- 136 -
Tabulka 6: Příklad tabulky logů v LMS Moodle (identifikátory byly anonymizovány). -----	- 159 -
Tabulka 7: Deskriptivní popis nezávisle proměnných (tj. prediktorů). -----	- 163 -
Tabulka 8: Srovnání přesnosti, senzitivity, specificity a plochy pod křivkou u analyzovaných klasifikačních algoritmů při použití kompletních dat a výchozí metody validace. -----	- 173 -
Tabulka 9: Důležitost jednotlivých proměnných v modelu u analyzovaných klasifikačních algoritmů při použití kompletních dat. Ve všech případech platí, čím větší číslo, tím větší důležitost. V závorkách jsou uvedeny relativní hodnoty důležitosti. -----	- 175 -
Tabulka 10: Srovnání přesnosti, senzitivity, specificity a plochy pod křivkou u analyzovaných klasifikačních algoritmů při použití externí validace se 100 opakováními (bez zohlednění úrovně kurzů). -----	- 176 -
Tabulka 11: Srovnání přesnosti, senzitivity, specificity a plochy pod křivkou u analyzovaných klasifikačních algoritmů při použití externí validace se 100 opakováními zohledňující úroveň kurzů. -----	- 177 -
Tabulka 12: Četnosti výskytu jednotlivých typů interakce mezi studenty a učiteli v online diskuzních fórech v rámci kurzů v LMS. -----	- 216 -
Tabulka 13: Základní ukazatele interakce v diskuzních fórech dle jednotlivých typů interakce. Vzhledem k výraznému zešíkmení rozdělení u většiny proměnných je jakožto průměrný počet reportován medián místo aritmetického	

průměru. V závorce je pak vždy uvedeno mezikvartilové rozpětí jakožto míra rozptýlenosti.-----	- 217 -
Tabulka 14: Vybrané základní ukazatele interakce v diskuzních fórech dle jednotlivých podtypů interakce. Opět je reportován medián a mezikvartilové rozpětí (v závorce).-----	- 218 -
Tabulka 15: SNA ukazatele interakce v diskuzních fórech dle jednotlivých podtypů základního typu B. Reportován medián a mezikvartilové rozpětí (v závorce).-----	- 219 -
Tabulka 16: SNA ukazatele interakce v diskuzních fórech dle jednotlivých podtypů základního typu C. Reportován medián a mezikvartilové rozpětí (v závorce).-----	- 220 -
Tabulka 17: SNA ukazatele interakce v diskuzních fórech dle jednotlivých podtypů základního typu D. Reportován medián a mezikvartilové rozpětí (v závorce).-----	- 221 -
Tabulka 18: Přehled základních charakteristik analyzovaných testů.-----	- 238 -
Tabulka 19: Přehled základních názvů aktivit v průběhu plnění testu po předzpracování dat.-----	- 240 -
Tabulka 20: Příklady názvů dalších aktivit (tj. aktivit mimo samotný test) po předzpracování dat.-----	- 241 -

## Použitá literatura

- Abu Khoua, E., & Atif, Y. (2018). Social network analysis to influence career development. *Journal of Ambient Intelligence and Humanized Computing*, 9(3), 601–616.
- Aggarwal, J. (2014). *Essentials of Educational Technology: Innovations in teaching–learning*. New Delhi: Vikas Publishing House.
- Agrawal, R., Imieliński, T., & Swami, A. (1993). Mining association rules between sets of items in large databases. In *SIGMOD '93 Proceedings of the 1993 ACM SIGMOD international conference on Management of data* (s. 207–216). New York, NY: ACM.
- Agudo-Peregrina, Á. F., Iglesias-Pradas, S., Conde-González, M. Á., & Hernández-García, Á. (2014). Can we predict success from log data in VLEs? Classification of interactions for learning analytics and their relation with performance in VLE-supported F2F and online learning. *Computers in Human Behavior*, 31, 542–550.
- Akçapınar, G., Hasnine, M. N., Majumdar, R., Flanagan, B., & Ogata, H. (2019). Developing an early-warning system for spotting at-risk students by using eBook interaction logs. *Smart Learning Environments*, 6(4).
- Alhajj, R., & Rokne, J. (Eds.). (2014). *Encyclopedia of social network analysis and mining*. New York: Springer.
- AlJarrah, A., Thomas, M. K., & Shehab, M. (2018). Investigating temporal access in a flipped classroom: procrastination persists. *International Journal of Educational Technology in Higher Education*, 15(1), 1–18.
- Anderson, M., & Gavan, C. (Eds.). (2016). *Developing Effective Educational Experiences through Learning Analytics*. Hershey, PA: IGI Global.
- Anderson, T. (2008). *Theory and practice of online learning*. Edmonton: AU Press.
- Andrews, R., & Haythornthwaite, C. (2007). Introduction to E-learning Research. In R. Andrews, & C. Haythornthwaite (Eds.), *The SAGE Handbook of E-learning Research* (s. 1–52). London: SAGE Publications.
- Annetta, L. A., Folta, E., & Klesath, M. (2010). *V-Learning: Distance Education in the 21st Century Through 3D Virtual Learning Environments*. Dordrecht: Springer.
- Arnold, K. E., & Pistilli, M. D. (2012). Course Signals at Purdue: Using Learning Analytics to Increase Student Success. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*. New York, USA: ACM Press.

- Arnseth, H., Erstad, O., Juhaňák, L., & Zounek, J. (2016). Pedagogika a nové výzvy výzkumu ICT: role digitálních technologií v každodenním životě a učení mládeže. *Studia Paedagogica*, 21(1), 87–110.
- Arulchelvan, S. (2011). Online Interactive Forums as a Learning Tool among the Media Students – An Analysis. *Turkish Online Journal of Distance Education*, 12(4), 58–67.
- Aung, K. Z., & Myo, N. N. (2017). Sentiment analysis of students' comment using lexicon based approach. In *16th IEEE/ACIS International Conference on Computer and Information Science* (s. 149–154). Wuhan, China: IEEE.
- Awad, M., & Khanna, R. (2015). *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*. Apress.
- Babo, R., & Azevedo, A. (2012). *Higher Education Institutions and Learning Management Systems: Adoption and Standardization*. Hershey: IGI Global.
- Baker, R. S. (2007). Modeling and understanding students' off-task behavior in intelligent tutoring systems. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems* (s. 1059–1068). New York: ACM.
- Baker, R. S., & Gowda, S. M. (2010). An analysis of the differences in the frequency of students' disengagement in urban, rural, and suburban high schools. In *Educational Data Mining 2010: 3rd International Conference on Educational Data Mining, Pittsburgh, PA, USA, June 11-13, 2010*.
- Baker, R. S., & Inventado, P. S. (2014). Educational Data Mining and Learning Analytics. In J. A. Larusson, & B. White (Eds.), *Learning Analytics: From Research to Practice* (s. 61–75). New York: Springer.
- Baker, R. S., & Yacef, K. (2009). The State of Educational Data Mining in 2009: A Review and Future Visions. *Journal of Educational Data Mining*, 1(1), 3–17.
- Baker, R. S., de Carvalho, A., Raspat, J., Alevan, V., Corbett, A. T., & Koedinger, K. R. (2009). Educational software features that encourage and discourage “Gaming the System”. In *Proceedings of the 14th International Conference on Artificial Intelligence in Education*. Brighton: IOS Press.
- Baker, R. S., D'Mello, S. K., Rodrigo, M. T., & Graesser, A. C. (2010). Better to be frustrated than bored: The incidence, persistence, and impact of learners' cognitive–affective states during interactions with three different computer-based learning environments. *International Journal of Human-Computer Studies*, 68(4), 223–241.

- Baker, R. S., Goldstein, A. B., & Heffernan, N. T. (2011). Detecting Learning Moment-by-Moment. *International Journal of Artificial Intelligence in Education*, 21(1–2), 5–25.
- Baker, R. S., Lindrum, D., Lindrum, M. J., & Perkowski, D. (2015). Analyzing Early At-Risk Factors in Higher Education e-Learning Courses. In *Proceedings of the 8th International Conference on Educational Data Mining*. Madrid.
- Baker, R. S., Martin, T., & Rossi, L. M. (2017). Educational Data Mining and Learning Analytics. In A. A. Rupp, & J. P. Leighton (Eds.), *The Handbook of Cognition and Assessment: Frameworks, Methodologies, and Applications* (s. 379–396). Wiley-Blackwell.
- Bakhshinategh, B., Zaiane, O. R., ElAtia, S., & Ipperciel, D. (2018). Educational data mining applications and tasks: A survey of the last 10 years. *Education and Information Technologies*, 23(1), 537–553.
- Baneres, D., Elena Rodríguez, M., Guerrero-Roldán, A.-E., & Baró, X. (2016). Towards an Adaptive e-Assessment System Based on Trustworthiness. In S. Caballé, & R. Clarisó (Eds.), *Formative Assessment, Learning Data Analytics and Gamification: In ICT Education* (s. 25-47). London: Academic Press.
- Bannert, M., Reimann, P., & Sonnenberg, C. (2014). Process mining techniques for analysing patterns and strategies in students' self-regulated learning. *Metacognition and Learning*, 9(2), 161–185.
- Barabási, A.-L. (2005). *V pavučině sítí*. Praha: Paseka.
- Bastian, M., Heymann, S., & Jacomy, M. (2009). Gephi: An Open Source Software for Exploring and Manipulating Networks. In *Proceedings of the Third International Conference on Weblogs and Social Media* (s. 361–362). San Jose, California,: AAAI Press.
- Bayer, J., Bydžovská, H., Géryk, J., Obšiač, T., & Popelínský, L. (2012). Predicting drop-out from social behaviour of students. In *Proceedings of the 5th International Conference on Educational Data Mining* (s. 103–109). Chania: International Educational Data Mining Society.
- Beck, J. E. (2005). Engagement tracing: using response times to model student disengagement. In C.-K. Looi, G. McCalla, B. Bredeweg, & J. Brueker (Eds.), *Artificial intelligence in education: supporting learning through intelligent and socially informed technology*. Amsterdam: IOS Press.
- Behrens, J. T. (1997). Principles and Procedures of Exploratory Data Analysis. *Psychological Methods*, 2(2), 131–160.

- Berland, M., Baker, R. S., & Blikstein, P. (2014). Educational Data Mining and Learning Analytics: Applications to Constructionist Research. *Technology, Knowledge and Learning*, 19(1–2), 205–220.
- Bienkowski, M., Feng, M., & Means, B. (2012). *Enhancing teaching and learning through educational data mining and learning analytics*. Washington, DC: U.S. Department of Education. Dostupné z <https://tech.ed.gov/wp-content/uploads/2014/03/edmla-brief.pdf>
- Bihani, A., Ullman, J., & Paepcke, A. (2018). FAQtor : Automatic FAQ generation using online forums. In *Proceedings of the 11th International Conference on Educational Data Mining* (s. 529–532). International Educational Data Mining Society.
- Blaikie, N. (2003). *Analyzing Quantitative Data: From Description to Explanation*. London: Sage.
- Blikstein, P., & Worsley, M. (2016). Multimodal Learning Analytics and Education Data Mining: Using Computational Technologies to Measure Complex Learning Tasks. *Journal of Learning Analytics*, 3(2), 220–238.
- Bodily, R., & Verbert, K. (2017). Review of Research on Student-Facing Learning Analytics Dashboards and Educational Recommender Systems. *IEEE Transactions on Learning Technologies*, 10(4), 405–418.
- Bosch, N., & D’Mello, S. K. (2017). The Affective Experience of Novice Computer Programmers. *International Journal of Artificial Intelligence in Education*, 27(1), 181–206.
- Bousbia, N., & Belamri, I. (2014). Which Contribution Does EDM Provide to Computer-Based Learning Environments? In A. Peña-Ayala (Ed.), *Educational Data Mining: Applications and Trends*. New York: Springer.
- Bozdag, E. (2013). Bias in algorithmic filtering and personalization. *Ethics and Information Technology*, 15(3), 209–227.
- Breiman, L. (2001). Statistical Modeling: The Two Cultures (with comments and a rejoinder by the author). *Statistical science*, 16(3), 199–231.
- Broadbent, J. (2017). Comparing online and blended learner's self-regulated learning strategies and academic performance. *Internet and Higher Education*, 33, 24–32.
- Brooks, C., Greer, J., & Gutwin, C. (2014). The Data-Assisted Approach to Building Intelligent Technology-Enhanced Learning Environments. In J. A. Larusson, & B. White (Eds.), *Learning Analytics: From Research to Practice* (s. 123–156). New York: Springer.



- Brooks, C., Johnston, G. S., Thompson, C., & Greer, J. (2013). Detecting and Categorizing Indices in Lecture Video Using Supervised Machine Learning. In O. R. Zaïane, & S. Zilles (Eds.), *Advances in Artificial Intelligence* (s. 241–247). Berlin: Springer.
- Brusilovsky, P. (2001). Adaptive hypermedia: From intelligent tutoring systems to web-based education. *User Modeling and User-Adapted Interaction*, 11(1/2), 87–110.
- Buckingham Shum, S. (2012). *Learning analytics*. UNESCO Institute for Information Technologies in Education. Dostupné z <http://iite.unesco.org/pics/publications/en/files/3214711.pdf>
- Buckingham Shum, S., & Ferguson, R. (2012). Social Learning Analytics. *Educational Technology & Society*, 15(3), 3–26.
- Buchanan, T. (2002). Online assessment: Desirable or dangerous? *Professional Psychology: Research and Practice*, 33(2), 148–154.
- Burgerová, J., & Adamkovičová, M. (2014). *Vybrané aspekty komunikačnej dimenzie e-learningu*. Prešov: Pedagogická fakulta Prešovskej univerzity v Prešove.
- Byčkovský, P. (1982). *Základy měření výsledků výuky: Tvorba didaktického testu*. Praha: ČVUT.
- Bydžovská, H. (2016a). A Comparative Analysis of Techniques for Predicting Student Performance. In *Proceedings of the 9th International Conference on Educational Data Mining* (s. 306–311). Raleigh: International Educational Data Mining Society.
- Bydžovská, H. (2016b). *Towards Prediction and Recommendation in Higher Education*. Brno: Masarykova univerzita, Fakulta informatiky. Dostupné z <https://is.muni.cz/th/kska0/>
- Bydžovská, H., & Popelínský, L. (2013). Predicting Student Performance in Higher Education. *DEXA '13: 24th International Conference on Database and Expert Systems Applications* (s. 141–145). Prague: IEEE Computer Society.
- Calders, T., & Pechenizkiy, M. (2011). Introduction to the special section on educational data mining. *SIGKDD Explorations*, 13(2), 3–6.
- Calvet Liñán, L., & Juan Pérez, A. A. (2015). Educational Data Mining and Learning Analytics: differences, similarities, and time evolution. *RUSC. Universities and Knowledge Society Journal*, 12(3), 98–112.
- Campbell, J. P., & Oblinger, D. G. (2007). *Academic analytics*. Washington, DC: EDUCAUSE Center for Applied Research. Dostupné z <https://www.educause.edu/ir/library/pdf/PUB6101.pdf>
- Campbell, J. P., DeBlois, P. B., & Oblinger, D. G. (2007). Academic analytics: A new tool for a new era. *Educause Review*, 42(4), 40–57.

- Carmichael, I., & Marron, J. S. (2018). Data science vs. statistics: two cultures? *Japanese Journal of Statistics and Data Science*, 1(1), 117–138.
- Carolan, B. V. (2013). *Social network analysis and educational research: Theory, methods, and applications*. Thousand Oaks: SAGE Publications.
- Castro, F., Vellido, A., Nebot, À., & Mugica, F. (2007). Applying Data Mining Techniques to e-Learning Problems. In L. C. Jain, R. A. Tedman, & D. K. Tedman (Eds.), *Evolution of Teaching and Learning Paradigms in Intelligent Environment*. Berlin, Heidelberg: Springer.
- Cleveland, W. S. (2001). Data Science: an Action Plan for Expanding the Technical Areas of the Field of Statistics. *International Statistical Review*, 69(1), 21–26.
- Clow, D. (2013). An overview of learning analytics. *Teaching in Higher Education*, 18(6), 683–695.
- Cohen, L., Manion, L., & Morrison, K. (2007). *Research Methods in Education* (6th ed.). London: Routledge.
- Conole, G., & Oliver, M. (Eds.). (2007). *Contemporary Perspectives in E-learning Research: Themes, methods and impact on practice*. London: Routledge.
- Cooper, A. (2012a). What is analytics? Definitions and essential characteristics. *JISC CETIS Analytics Series*, 1(5), 1–10. Dostupné z <http://publications.cetis.org.uk/wp-content/uploads/2012/11/What-is-Analytics-Vol1-No-5.pdf>
- Cooper, A. (2012b). A brief history of analytics. *JISC CETIS Analytics Series*, 1(9), 1–21. Dostupné z <http://publications.cetis.org.uk/wp-content/uploads/2012/12/Analytics-Brief-History-Vol-1-No9.pdf>
- Corbeil, J. R., & Corbeil, M. E. (2015). E-learning: Past, Present, and Future. In B. H. Khan, & M. Ally (Eds.), *International Handbook of E-learning, Volume 1: Theoretical Perspectives and Research* (s. 51–64). London: Routledge.
- Corbett, A. T., & Anderson, J. R. (1994). Knowledge tracing: Modeling the acquisition of procedural knowledge. *User Modeling and User-Adapted Interaction*, 4(4), 253–278.
- Costa, E. B., Fonseca, B., Santana, M. A., de Araújo, F. F., & Rego, J. (2017). Evaluating the effectiveness of educational data mining techniques for early prediction of students' academic failure in introductory programming courses. *Computers in Human Behavior*, 73, 247–256.
- Creswell, J. W. (2009). *Research Design: Qualitative, Quantitative and Mixed Methods* (3rd ed.). Thousand Oaks: Sage.

- Csárdi, G., & Nepusz, T. (2006). The igraph software package for complex network research. *InterJournal, Complex Systems* (1695), 1–9.
- D’Mello, S. K. (2017). Emotional Learning Analytics. In C. Lang, G. Siemens, A. Wise, & D. Gašević (Eds.), *Handbook of Learning Analytics* (s. 115–127). Society for Learning Analytics Research.
- D’Mello, S. K., & Graesser, A. (2011). The half-life of cognitive-affective states during complex learning. *Cognition and Emotion*, 25(7), 1299–1308.
- D’Mello, S. K., & Graesser, A. C. (2012). AutoTutor and Affective AutoTutor: Learning by Talking with Cognitively and Emotionally Intelligent Computers that Talk Back. *ACM Transactions on Interactive Intelligent Systems*, 2(4), 23:1–23:39.
- D’Mello, S. K., & Graesser, A. C. (2015). Feeling, Thinking, and Computing with Affect-Aware Learning Technologies. In R. A. Calvo, S. K. D’Mello, J. Gratch, & A. Kappas (Eds.), *The Oxford Handbook of Affective Computing* (s. 628–649). New York: Oxford University Press.
- D’Mello, S. K., Craig, S. D., Witherspoon, A., McDaniel, B., & Graesser, A. C. (2008). Automatic detection of learner’s affect from conversational cues. *User Modeling and User-Adapted Interaction*, 18(1–2), 45–80.
- D’Mello, S. K., Lehman, S., Pekrun, R., & Graesser, A. C. (2014). Confusion can be beneficial for learning. *Learning and Instruction*, 29(1), 153–170.
- Daly, A. J. (Ed.). (2010). *Social network theory and educational change*. Cambridge: Harvard Education Press.
- Daniel, B. K. (Ed.). (2017). *Big Data and Learning Analytics in Higher Education: Current Theory and Practice*. New York: Springer.
- Davenport, T. H., & Patil, D. J. (2012). Data Scientist: The Sexiest Job of the 21st Century. *Harvard Business Review*, 2012(10). Dostupné z <https://hbr.org/2012/10/data-scientist-the-sexiest-job-of-the-21st-century>
- Davis, K. A. (2013). Using Low-and No-Stakes Quizzing for Student Self-Evaluation of Readiness for Exams. *International Journal of Construction Education and Research*, 9(4), 256–271.
- Dawson, S., Gašević, D., Siemens, G., & Joksimović, S. (2014). Current state and future trends: A citation network analysis of the learning analytics field. In *Proceedings of the Fourth International Conference on Learning Analytics And Knowledge* (s. 231–240). New York: ACM.
- Dawson, S., Mirriahi, N., & Gašević, D. (2015). Importance of Theory in Learning Analytics in Formal and Workplace Settings. *Journal of Learning Analytics*, 2(2), 1–4.

- De Laat, M., & Schreurs, B. (2013). Visualizing Informal Professional Development Networks: Building a Case for Learning Analytics in the Workplace. *American Behavioral Scientist*, 57(10), 1421–1438.
- Dean, J. (2014). *Big Data, Data Mining, and Machine Learning: Value Creation for Business Leaders and Practitioners*. Hoboken: Wiley.
- Dennen, V. P. (2005). From message posting to learning dialogues: Factors affecting learner participation in asynchronous discussion. *Distance Education*, 26(1), 127–148.
- Dennen, V. P. (2008). Pedagogical lurking: Student engagement in non-posting discussion behavior. *Computers in Human Behavior*, 24(4), 1624–1633.
- Desmarais, M. C., & Baker, R. S. (2012). A review of recent advances in learner and skill modeling in intelligent learning environments. *User Modeling and User-Adapted Interaction*, 22(1–2), 9–38.
- Dias, S. B., Diniz, J. A., & Hadjileontiadis, L. J. (2014). *Towards an Intelligent Learning Management System Under Blended Learning: Trends, Profiles and Modeling Perspectives*. Cham: Springer.
- Disco. (2019). Fluxicon: Process mining for professionals. Dostupné z <https://fluxicon.com/disco/>
- Disman, M. (2008). *Jak se vrábí sociologická znalost*. Praha: Univerzita Karlova v Praze.
- Donoho, D. (2017). 50 Years of Data Science. *Journal of Computational and Graphical Statistics*, 26(4), 745–766.
- Dringus, L. P. (2012). Learning analytics considered harmful. *Journal of Asynchronous Learning Networks*, 16(3), 87–100.
- Dutt, A., Ismail, M. A., & Herawan, T. (2017). A Systematic Review on Educational Data Mining. *IEEE Access*, 5, 15991–16005.
- Dyckhoff, A. L., Zielke, D., Bultmann, M., Chatti, M. A., & Schroeder, U. (2012). Design and Implementation of a Learning Analytics Toolkit for Teachers. *Educational Technology & Society*, 15(3), 58–76.
- Ebbinghaus, H. (1885). *Memory: A contribution to experimental psychology*. New York: Teachers College, Columbia University.
- Echeverría, V., Avendaño, A., Chiluíza, K., Vásquez, A., & Ochoa, X. (2014). Presentation Skills Estimation Based on Video and Kinect Data Analysis. In *Proceedings of the 2014 ACM workshop on Multimodal Learning Analytics Workshop and Grand Challenge* (s. 53–60 ). New York: ACM.
- ELAtia, S., Ipperciel, D., & Zaïane, O. R. (Eds.). (2016). *Data Mining and Learning Analytics: Applications in Educational Research*. Hoboken, New Jersey: Wiley.

- Emons, W. H., Sijtsma, K., & Meijer, R. R. (2005). Global, Local, and Graphical Person-Fit Analysis Using Person-Response Functions. *Psychological Methods*, *10*(1), 101–119.
- Essa, A. (2016). A possible future for next generation adaptive learning systems. *Smart Learning Environments*, *3*(1), 1–24.
- Estacio, R. R., & Raga, R. C. (2017). Analyzing students online learning behavior in blended courses using Moodle. *Asian Association of Open Universities Journal*, *12*(1), 52–68.
- Everitt, B. S. (2002). *The Cambridge Dictionary of Statistics*. Cambridge: Cambridge University Press.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From Data Mining to Knowledge Discovery in Databases. *AI Magazine*, *17*(3), 37–54.
- Fazeli, S., Drachsler, H., Brouns, F., & Sloep, P. (2014). Towards a Social Trust-Aware Recommender for Teachers. In N. Manouselis, H. Drachsler, K. Verbert, & O. C. Santos (Eds.), *Recommender Systems for Technology Enhanced Learning: Research Trends and Applications* (s. 177–194). New York: Springer.
- Ferguson, R. (2012a). Learning analytics: drivers, developments and challenges. *International Journal of Technology Enhanced Learning*, *4*(5/6), 304–317.
- Ferguson, R. (2012b). *The State Of Learning Analytics in 2012: A Review and Future Challenges*. Technical Report KMI-12-01, Knowledge Media Institute, The Open University, UK. Dostupné z <http://kmi.open.ac.uk/publications/techreport/kmi-12-01>
- Ferguson, R., & Buckingham Shum, S. (2012). Social learning analytics: five approaches. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (s. 23–33). New York: ACM.
- Ferguson, R., Brasher, A., Clow, D., Cooper, A., Hillaire, G., Mittelmeier, J., . . . Vuorikari, R. (2016). *Research Evidence on the Use of Learning Analytics - Implications for Education Policy*. (R. Vuorikari, & J. Castaño Muñoz, Eds.) Luxembourg: Publications Office of the European Union.
- Fictumová, J. (2004). Učitelé vytvářejí kurzy na webu. In J. Rambousek, & D. Mikšík (Eds.), *E learning přichází* (s. 39–44). Brno: Masarykova univerzita.
- Fidalgo, P., & Thormann, J. (2012). A Social Network Analysis Comparison of an Experienced and a Novice Instructor in Online Teaching. *European Journal of Open, Distance and E-Learning*, *2012*(1).
- Frank, E., Hall, M. A., & Witten, I. H. (2016). *The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques"*. San Francisco,

- CA: Morgan Kaufmann. Dostupné z [https://www.cs.waikato.ac.nz/ml/weka/Witten\\_et\\_al\\_2016\\_appendix.pdf](https://www.cs.waikato.ac.nz/ml/weka/Witten_et_al_2016_appendix.pdf)
- Freedman, D. H. (2010). Why scientific studies are so often wrong: The streetlight effect. *Discover*, 26. Dostupné z <http://discovermagazine.com/2010/jul-aug/29-why-scientific-studies-often-wrong-streetlight-effect>
- Fritz, J. (2011). Classroom walls that talk: Using online course activity data of successful students to raise self-awareness of underperforming peers. *The Internet and Higher Education*, 14(2), 89–97.
- Fruchterman, T. M., & Reingold, E. M. (1991). Graph Drawing by Force-directed Placement. *Software - Practice and Experience*, 21(11), 1129–1164.
- Gao, F. (2014). Exploring the Use of Discussion Strategies and Labels in Asynchronous Online Discussion. *Online Learning*, 18(3).
- García-Saiz, D., & Zorilla Pantaleón, M. E. (2011). E-learning Web Miner: A data mining application to help instructors involved in virtual courses. In M. Pechenizkiy, T. Calders, C. Conati, S. Ventura, C. Romero, & J. Stamper (Eds.), *Proceedings of the 4th International Conference on Educational Data Mining* (s. 323–324). Eindhoven: Eindhoven University of Technology.
- Gašević, D., Dawson, S., & Siemens, G. (2015). Let's not forget: Learning analytics are about learning. *TechTrends*, 59(1), 64–71.
- Gašević, D., Dawson, S., Rogers, T., & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *Internet and Higher Education*, 28, 68–84.
- Gašević, D., Zouaq, A., & Janzen, R. (2013). "Choose Your Classmates, Your GPA Is at Stake!" The Association of Cross-Class Social Ties and Academic Performance. *American Behavioral Scientist*, 57(10), 1460–1479.
- Gavora, P. (2008). *Úvod do pedagogického výskumu*. Bratislava: Univerzita Komenského Bratislava.
- Gaytan, J., & McEwen, B. C. (2007). Effective online instructional and assessment strategies. *The American Journal of Distance Education*, 21(3), 117–132.
- Géryk, J., & Popelínský, L. (2014). Analysis of Student Retention and Drop-out using Visual Analytics. In *Proceedings of the 7th International Conference on Educational Data Mining* (s. 331–332). London: International Educational Data Mining Society.
- Ghadirian, H., Salehi, K., & Ayub, A. F. (2018). Analyzing the Social Networks of High- and Low-Performing Students in Online Discussion Forums. *American Journal of Distance Education*, 32(1), 27–42.

- Gitinabard, N., Xu, Y., Heckman, S. S., Barnes, T., & Lynch, C. F. (2019). How Widely Can Prediction Models Be Generalized? Performance Prediction in Blended Courses. *IEEE Transactions on Learning Technologies*, *12*(2), 184–197.
- Goldstein, P. J., & Katz, R. N. (2005). *Academic Analytics: The Uses of Management Information and Technology in Higher Education*. ECAR Research Study 8. Dostupné z <http://net.educause.edu/ir/library/pdf/ers0508/rs/ers0508w.pdf>
- González Nespereira, C., Dai, K., Díaz Redondo, R. P., & Fernández Vilas, A. (2014). Is the LMS access frequency a sign of students' success in face-to-face higher education?. In *Proceedings of the Second International Conference on Technological Ecosystems for Enhancing Multiculturality* (s. 283–290). New York: ACM.
- González Nespereira, C., Fernández Vilas, A., & Díaz Redondo, R. P. (2015). Am I failing this course?: risk prediction using e-learning data. In *Proceedings of the 3rd International Conference on Technological Ecosystems for Enhancing Multiculturality* (s. 271–276). New York: ACM.
- Gorunescu, F. (2011). *Data Mining: Concepts, Models and Techniques*. Berlin, Heidelberg: Springer.
- Govaerts, S., Verbert, K., Duval, E., & Pardo, A. (2012). The student activity meter for awareness and self-reflection. *Extended Abstracts on Human Factors in Computing Systems* (s. 869–884). New York, USA: ACM Press.
- Graf, S., Ives, C., Rahman, N., & Ferri, A. (2011). AAT: a tool for accessing and analysing students' behaviour data in learning systems. In *Proceedings of the 1st International Conference on Learning Analytics and Knowledge* (s. 174–179 ). New York, USA: ACM Press.
- Greller, W., & Drachsler, H. (2012). Translating Learning into Numbers: A Generic Framework for Learning Analytics. *Educational Technology & Society*, *15*(3), 42–57.
- Günther, C. W., & van der Aalst, W. M. (2007). Fuzzy mining - adaptive process simplification based on multi-perspective metrics. In G. Alonso, P. Dadam, & M. Rosemann (Ed.), *Proceedings of the 5th International Conference on Business Process Management*. Brisbane, Australia.
- Guyon, I., & Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research*, *3*, 1157–1182.
- Hadwin, A. F., Nesbit, J. C., Jamieson-Noel, D., Code, J., & Winne, P. H. (2007). Examining trace data to explore self-regulated learning. *Metacognition and Learning*, *2*(2–3), 107–124.

- Hájek, P., Havel, I., & Chytil, M. (1966). The GUHA method of automatic hypotheses determination. *Computing*, 1(4), 293–308.
- Hajjem, A., Bellavance, F., & Larocque, D. (2014). Mixed-effects random forest for clustered data. *Journal of Statistical Computation and Simulation*, 84(6), 1313–1328.
- Han, J., & Kamber, M. (2006). *Data Mining: Concepts and Techniques*. San Francisco, CA: Morgan Kaufmann.
- Hashem, I. A., Yaqoob, I., Anuar, N. B., Mokhtar, S., Gani, A., & Khan, S. U. (2015). The rise of “big data” on cloud computing: Review and open research issues. *Information Systems*, 47, 98–115.
- Havlová, J. (2003). Uzavřený software. *KTD: Česká terminologická databáze knihovnictví a informační vědy (TDKIV)*. Praha: Národní knihovna ČR. Dostupné z [http://aleph.nkp.cz/F/?func=direct&doc\\_number=000014974&local\\_base=KTD](http://aleph.nkp.cz/F/?func=direct&doc_number=000014974&local_base=KTD)
- Hayashi, C. (1998). What is Data Science? Fundamental Concepts and a Heuristic Example. In C. Hayashi, K. Yajima, H. H. Bock, N. Ohsumi, Y. Tanaka, & Y. Baba (Eds.), *Data Science, Classification, and Related Methods* (s. 40–51). Springer Japan.
- Haythornthwaite, C., de Laat, M., & Schreurs, B. (2016). A Social Network Analytic Perspective on E-Learning. In C. Haythornthwaite, R. Andrews, J. Fransman, & E. M. Meyers (Eds.), *The SAGE Handbook of E-learning Research* (2nd ed., 251–269). SAGE: London.
- Hebák, P. (2013). *Statistické myšlení a nástroje analýzy dat*. Praha: Informatorium.
- Hecking, T., Ziebarth, S., & Hoppe, H. U. (2014). Analysis of Dynamic Resource Access Patterns in Online Courses. *Journal of Learning Analytics*, 1(3), 34–60.
- Heffernan, N., & Heffernan, C. (2014). The ASSISTments ecosystem: Building a platform that brings scientists and teachers together for minimally invasive research on human learning and teaching. *International Journal of Artificial Intelligence in Education*, 24(4), 470–497.
- Hendl, J. (2012). *Přehled statistických metod: Analýza a metaanalýza dat*. Praha: Portál.
- Hendl, J. (2014). *Statistika v aplikacích*. Praha: Portál.
- Heo, H., Lim, K. Y., & Kim, Y. (2010). Exploratory study on the patterns of online interaction and knowledge co-construction in project-based learning. *Computers & Education*, 55(3), 1383–1392.
- Hernández-García, Á., González-González, I., Jiménez-Zarco, A. I., & Chaparro-Peláez, J. (2015). Applying social learning analytics to message boards in online distance learning: A case study. *Computers in Human Behavior*, 47, 68–80.



- Hershkovitz, A., & Nachmias, R. (2011). Online persistence in higher education web-supported courses. *Internet and Higher Education*, 14(2), 98–106.
- Hershkovitz, A., Baker, R. S., Gobert, J., Wixon, M., & Sao Pedro, M. (2013). Discovery With Models: A Case Study on Carelessness in Computer-Based Science Inquiry. *American Behavioral Scientist*, 57(10), 1480–1499.
- Hilbert, M. (2016). Big Data for Development: A Review of Promises and Challenges. *Development Policy Review*, 34(1), 135–174.
- Holčík, J., & Komenda, M. (Eds.). (2015). *Matematická biologie: e-learningová učebnice* [online]. Brno: Masarykova univerzita. Dostupné z <http://portal.matematickabiologie.cz>
- Hostičková, I. (2014). *Vývoj paradigmat výzkumu umělé inteligence*. Praha: Univerzita Karlova v Praze.
- Howard, E., Meehan, M., & Parnell, A. (2018). Contrasting prediction methods for early warning systems at undergraduate level. *The Internet and Higher Education*, 37, 66–75.
- Hrastinski, S. (2008). What is online learner participation? A literature review. *Computers & Education*, 51(4), 1755–1765.
- Hrastinski, S. (2009). A theory of online learning as online participation. *Computers & Education*, 52(1), 78–82.
- Huang, A. Y., Lu, O. H., Huang, J. C., Yin, C. J., & Yang, S. J. (2019). Predicting students' academic performance by using educational big data and learning analytics: evaluation of classification methods and learning logs. *Interactive Learning Environments*, 1–25.
- Chambers, J. M. (1993). Greater or lesser statistics: A choice for future research. *Statistics and Computing*, 3(4), 182–184.
- Chatfield, C. (1988). *Problem Solving: A Statistician's Guide*. London: Chapman and Hall.
- Chatti, M. A., Dyckhoff, A. L., Schroeder, U., & Thüs, H. (2012). A Reference Model for Learning Analytics. *International Journal of Technology Enhanced Learning*, 4(5/6), 318–331.
- Chernobilsky, E., Ries, E., & Jasmine, J. (2016). Data Mining and Action Research. In S. ElAtia, D. Ipperciel, & O. R. Zaiane (Eds.), *Data Mining and Learning Analytics: Applications in Educational Research* (s. 67–78). Hoboken, NJ: John Wiley & Son.
- Chráška, M. (1999). *Didaktické testy*. Brno: Paido.
- Chrysafiadi, K., & Virvou, M. (2013). Student modeling approaches: A literature review for the last decade. *Expert Systems with Applications*, 40(11), 4715–4729.

- Ifenthaler, D., & Schumacher, C. (2016). Student perceptions of privacy principles for learning analytics. *Educational Technology Research and Development*, 64(5), 923–938.
- Inselberg, A. (1985). The plane with parallel coordinates. *The Visual Computer*, 1(2), 69–91.
- Ivančević, V., Knežević, M., Pušić, B., & Luković, L. (2014). Adaptive Testing in Programming Courses Based on Educational Data Mining Techniques. In A. Peña-Ayala (Ed.), *Educational Data Mining: Applications and Trends* (s. 257–287). Cham: Springer.
- Januszewski, A., & Molenda, M. (2008). *Educational Technology: A Definition with Commentary*. New York: Erlbaum.
- Jayaprakash, S. M., Moody, E. W., Lauría, E. J., Regan, J. R., & Baron, J. D. (2014). Early alert of academically at-risk students: An open source analytics initiative. *Journal of Learning Analytics*, 1(1), 6–47.
- Jelínek, M., Květon, P., & Vobořil, D. (2011). *Testování v psychologii: Teorie odpovědi na položku a počítačové adaptivní testování*. Praha: Grada.
- Jewitt, C. (2012). *Technology, literacy and learning: A multimodal approach*. London: Routledge.
- Jifa, G., & Lingling, Z. (2014). Data, DIKW, Big data and Data science. *Procedia Computer Science*, 31, 814–821.
- Jo, I.-H., Kim, D., & Yoon, M. (2015). Constructing Proxy Variables to Measure Adult Learners' Time Management Strategies in LMS. *Educational Technology & Society*, 18(3), 214–225.
- Jo, I.-H., Park, Y., Kim, J., & Song, J. (2014). Analysis of Online Behavior and Prediction of Learning Performance in Blended Learning Environments. *Educational Technology International*, 15(2), 71–88.
- Johnson, L., Adams Becker, S., Cummins, M., Estrada, V., Freeman, A., & Ludgate, H. (2013). *NMC Horizon Report: 2013 Higher Education Edition*. Austin, Texas: The New Media Consortium.
- Johnson, L., Adams Becker, S., Estrada, V., & Freeman, A. (2014). *NMC Horizon Report: 2014 Higher Education Edition*. Austin, Texas: The New Media Consortium.
- Johnson, L., Adams, S., & Cummins, M. (2012). *The NMC Horizon Report: 2012 Higher Education Edition*. Austin, Texas: The New Media Consortium.
- Johnson, L., Smith, R., Willis, H., Levine, A., & Haywood, K. (2011). *The 2011 Horizon Report*. Austin, Texas: The New Media Consortium.

- Joksimović, S., Gašević, D., Loughin, T. M., Kovanović, V., & Hatala, M. (2015). Learning at distance: Effects of interaction traces on academic achievement. *Computers & Education*, 87, 204–217.
- Joksimović, S., Manataki, A., Gašević, D., Dawson, S., Kovanović, V., & de Kereki, I. F. (2016). Translating network position into performance: importance of centrality in different network configurations. In *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge* (s. 314–323). Edinburgh: ACM.
- Juhaňák, L. (2011). *Způsoby zapojení virtuálního pracovního prostředí do práce studentských projektových týmů*. Brno: Masarykova univerzita, Filozofická fakulta, Ústav české literatury a. Načteno z <https://is.muni.cz/th/bkp20/>
- Juhaňák, L. (2013). *Analytika učení a dolování dat v oblasti e-learningu*. Příspěvek prezentovaný na XXI. ročníku konference České asociace pedagogického výzkumu. Efektivita vzdělávání v proměnách společnosti, září 2013, Ústí nad Labem, Česká republika.
- Juhaňák, L. (2014a). *Analytika učení – o čem mluvíme a co už víme*. Příspěvek prezentovaný na konferenci AEDUCA, říjen 2014, Olomouc, Česká republika.
- Juhaňák, L. (2014b). *Na cestě k analytice učení a dolování z dat ve vzdělávání*. Příspěvek prezentovaný na konferenci ISVK - Interdisciplinární studentská vědecká konference doktorandů FPE, říjen 2014, Plzeň, Česká republika.
- Juhaňák, L. (2017). Sociální sítě autorů publikujících v pedagogických vědách v letech 2009–2013: exploratorní analýza. *Studia paedagogica*, 22(1), 9–36.
- Juhaňák, L., & Zounek, J. (2015). *Analyzing interaction between students in online discussion forums using social network analysis*. Příspěvek prezentovaný na konferenci ECER 2015: Education and Transition. Contributions from Educational Research, září 2015, Budapešť, Maďarsko.
- Juhaňák, L., & Zounek, J. (2016). Analytika učení: nový přístup ke zkoumání učení (nejen) ve virtuálním prostředí. *Pedagogická orientace*, 26(3), 560–583.
- Juhaňák, L., & Zounek, J. (2019). Learning Analytics: Challenges and Opportunities of Using Data Analysis in Education. In P. O. de Pablos, M. D. Lytras, X. Zhang, & K. T. Chui (Eds.), *Opening Up Education for Inclusivity Across Digital Economies and Societies*. Hershey, PA: IGI Global.
- Juhaňák, L., Zounek, J., & Rohlíková, L. (2019). Using process mining to analyze students' quiz-taking behavior patterns in a learning management system. *Computers in Human Behavior*, 92, 496–506.

- Juhaňák, L., Zounek, J., Záleská, K., Bárta, O., & Vlčková, K. (2018). The Relationship between Students' ICT Use and Their School Performance: Evidence from PISA 2015 in the Czech Republic. *Orbis Scholae, 12*(2), str. 37–64.
- Juhaňák, L., Zounek, J., Záleská, K., Bárta, O., & Vlčková, K. (2019). The relationship between the age at first computer use and students' perceived competence and autonomy in ICT usage: A mediation analysis. *Computers & Education, 141*.
- Kalhous, Z., & Obst, O. (2002). *Školní didaktika*. Praha: Portál.
- Kamath, R. S., & Kamat, R. K. (2016). *Educational Data Mining with R and Rattle*. River Publishers.
- Kats, Y. (Ed.). (2010). *Learning management system technologies and software solutions for online teaching: tools and applications*. New York: IGI Global.
- Kaushik, A. (2011). *Webová analytika 2.0: kompletní průvodce analýzami návštěvnosti*. Brno: Computer Press.
- Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2015). *Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies*. Cambridge: MIT Press.
- Kellogg, S., Booth, S., & Oliver, K. (2014). A social network perspective on peer supported learning in MOOCs for educators. *The International Review of Research in Open and Distributed Learning, 15*(5). doi:10.19173/irrodl.v15i5.1852
- Kibble, J. (2007). Use of unsupervised online quizzes as formative assessment in a medical physiology course: effects of incentives on student participation and performance. *Advances in Physiology Education, 31*(3), 253–260.
- Kim, D., Park, Y., Yoon, M., & Jo, I. H. (2016). Toward evidence-based learning analytics: Using proxy variables to improve asynchronous online discussion environments. *Internet and Higher Education, 30*, 30–43.
- Kim, D., Yoon, M., Jo, I. H., & Branch, R. M. (2018). Learning analytics to support self-regulated learning in asynchronous online courses: A case study at a women's university in South Korea. *Computers & Education, 127*, 233–251.
- Kim, J. (2015). A Study of Perceptual Typologies on Computer Based Assessment (CBA): Instructor and Student Perspectives. *Educational Technology & Society, 18*(2), 80–96.
- Kim, M., & Lee, E. (2012). A Multidimensional Analysis Tool for Visualizing Online Interactions. *Educational Technology & Society, 15*(3), 89–102.

- Kitsantas, A., & Dabbagh, N. L. (2010). *Learning to Learn with Integrative Learning Technologies (ILT): A Practical Guide for Academic Success*. Charlotte: Information Age Publishing.
- Klement, M., & Dostál, J. (2018). *Teorie, východiska, principy a rozvoj distančního vzdělávání realizovaného formou e-learningu*. Olomouc: Univerzita Palackého v Olomouci.
- Klerkx, J., Verbert, K., & Duval, E. (2017). Learning Analytics Dashboards. In C. Lang, G. Siemens, A. Wise, & D. Gašević (Eds.), *Handbook of Learning Analytics* (s. 143–150). Society for Learning Analytics Research.
- Knowlton, D. S. (2005). A Taxonomy of Learning Through Asynchronous Discussion. *Journal of Interactive Learning Research*, 16(2), 155–177.
- Koedinger, K. R., & Corbett, A. T. (2006). Cognitive tutors: Technology bringing learning science to the classroom. In K. Sawyer (Ed.), *The Cambridge handbook of the learning sciences* (s. 61–78). New York: Cambridge University Press.
- Kopecký, K. (2006). *E-learning (nejen) pro pedagogy*. Olomouc: Hanex.
- Kovanović, V., Gašević, D., Dawson, S., Joksimović, S., Baker, R. S., & Hatala, M. (2015a). Penetrating the black box of time-on-task estimation. In *Proceedings of the Fifth International Conference on Learning Analytics And Knowledge* (s. 184–193). Poughkeepsie, New York: ACM.
- Kovanović, V., Gašević, D., Dawson, S., Joksimović, S., Baker, R. S., & Hatala, M. (2015b). Does time-on-task matter? Implications for the validity of learning analytics findings. *Journal of Learning Analytics*, 2(3), 81–110.
- Kovanović, V., Joksimović, S., Gašević, D., Hatala, M., & Siemens, G. (2017). Content Analytics: The Definition, Scope, and an Overview of Published Research. In C. Lang, G. Siemens, A. Wise, & D. Gašević (Eds.), *Handbook of Learning Analytics* (s. 77–92). Society for Learning Analytics Research.
- Krumm, A., Means, B., & Bienkowski, M. (2018). *Learning Analytics Goes to School: A Collaborative Approach to Improving Education*. London: Routledge.
- Kuhn, M. (2018). *caret: Classification and Regression Training*. Dostupné z <https://CRAN.R-project.org/package=caret>
- Kuhn, T. S. (2008). *Struktura vědeckých revolucí*. Praha: OIKOYMENH.
- Kužilek, J., Hlosta, M., Herrmannová, D., Zdráhal, Z., & Wolff, A. (2015). OU Analyse: Analysing at-risk students at The Open University. *Learning Analytics Review*, no. LAK15-1, 1-14. Dostupné z <http://www.laceproject.eu/learning-analytics-review/analysing-at-risk-students-at-open-university/>

- Lai, F.-Q., & Lehman, J. D. (2017). *Learning and Knowledge Analytics in Open Education*. Springer.
- Lal, P. (2014). Designing Online Learning Strategies through Analytics. In F. J. García-Peñalvo, & A. M. Seoane-Pardo (Eds.), *Online Tutor 2.0: Methodologies and Case Studies for Successful Learning* (s. 1–15). Hershey, PA.
- Lang, C., Siemens, G., Wise, A., & Gašević, D. (Eds.). (2017). *Handbook of Learning Analytics*. Society for Learning Analytics Research.
- Larusson, J. A., & White, B. (Eds.). (2014). *Learning Analytics: From Research to Practice*. New York: Springer.
- Lawson, C., Beer, C., Rossi, D., Moore, T., & Fleming, J. (2016). Identification of ‘at risk’ students using learning analytics: the ethical dilemmas of intervention strategies in a higher education institution. *Educational Technology Research and Development*, 64(5), 957–968.
- Lee, Y.-H., & Jia, Y. (2014). Using response time to investigate students’ test-taking behaviors in a NAEP computer-based study. *Large-scale Assessments in Education*, 2(8), 1–24.
- Leony, D., Pardo, A., de la Fuente Valentín, L., de Castro, D. S., & Kloos, C. D. (2012). GLASS: A Learning Analytics Visualization Tool. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (s. 162–163). New York, USA: ACM Press.
- Lester, J., Klein, C., Johri, A., & Rangwala, H. (2018). *Learning Analytics in Higher Education: Current Innovations, Future Potential, and Practical Applications*. Routledge: London.
- Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. *R News*, 2(3), 18–22.
- Lin, S., & Luo, W. (2019). A New Multilevel CART Algorithm for Multilevel Data with Binary Outcomes. *Multivariate Behavioral Research*, 54(4), 578–592.
- Littlejohn, A. (2017). Learning and Work: Professional Learning Analytics. In C. Lang, G. Siemens, A. Wise, & D. Gašević (Eds.), *Handbook of Learning Analytics* (s. 269–277). Society for Learning Analytics Research.
- Lodge, J. M., Horvath, J. C., & Corrin, L. (Eds.). (2018). *Learning Analytics in the Classroom: Translating Learning Analytics Research for Teachers*. London: Routledge.
- Long, P., & Siemens, G. (2011). Penetrating the Fog: Analytics in Learning and Education. *Educause Review*, 46(5), 31–40.

- Lu, O. H., Huang, A. Y., Lin, A. J., Ogata, H., & Yang, S. J. (2018). Applying Learning Analytics for the Early Prediction of Students' Academic Performance in Blended Learning. *Educational Technology & Society*, 21(2), 220–232.
- Lykourantzou, I., Giannoukos, I., Nikolopoulos, V., Mpardis, G., & Loumos, V. (2009). Dropout prediction in e-learning courses through the combination of machine learning techniques. *Computers & Education*, 53, 950–965.
- Macfadyen, L. P., & Dawson, S. (2010). Mining LMS data to develop an early warning system for educators: a proof of concept. *Computers & Education*, 54(2), 588–599.
- Macfadyen, L. P., & Dawson, S. (2012). Numbers are not enough: Why e-learning analytics fail to inform an institutional strategic plan. *Educational Technology and Society*, 15(3), 149–163.
- Maňák, J. (1994). *Nárys didaktiky*. Brno: Masarykova univerzita.
- Maňák, J., Švec, Š., & Švec, V. (Eds.). (2005). *Slovník pedagogické metodologie*. Brno: Masarykova univerzita.
- Maněna, V. (2015). *Moderně s Moodle: jak využít e-learning ve svůj prospěch?* Praha: CZ.NIC.
- Manouselis, N., Drachsler, H., Verbert, K., & Duval, E. (2013). *Recommender Systems for Learning*. New York: Springer.
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Byers, A. H. (2011). *Big data: The next frontier for innovation, competition, and productivity*. McKinsey Global Institute. Dostupné z <https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/big-data-the-next-frontier-for-innovation>
- Marbouti, F., Diefes-Dux, H. A., & Madhavan, K. (2016). Models for early prediction of at-risk students in a course using standards-based grading. *Computers & Education*, 103, 1–15.
- Mareš, P., Rabušic, L., & Soukup, P. (2015). *Analýza sociálněvědních dat (nejen) v SPSS*. Brno: Masarykova univerzita.
- Mařík, V., Štěpánková, O., & Lažanský, J. (1993). *Umělá inteligence (1)*. Praha: Academia.
- Mason, R., & Rennie, F. (2006). *Elearning: the key concepts*. New York: Routledge.
- Matcha, W., Uzir, N. A., Gašević, D., & Pardo, A. (2019). A Systematic Review of Empirical Studies on Learning Analytics Dashboards: A Self-Regulated Learning Perspective. *IEEE Transactions on Learning Technologies*. doi:10.1109/TLT.2019.2916802
- Maxwell, J. A. (2013). *Qualitative Research Design: An Interactive Approach* (3rd ed.). Thousand Oaks: Sage.
- Mayer-Schönberger, V., & Cukier, K. (2014). *Big data*. Brno: Computer Press.

- McNamara, D. S., Graesser, A. C., McCarthy, P. M., & Cai, Z. (2014). *Automated evaluation of text and discourse with Coh-Metrix*. Cambridge, UK: Cambridge University Press.
- Meijer, R. R., & Sijtsma, K. (2001). Methodology Review: Evaluating Person Fit. *Applied Psychological Measurement*, 25(2), 107–135.
- Meijer, R. R., Niessen, A. S., & Tendeiro, J. N. (2016). A Practical Guide to Check the Consistency of Item Response Patterns in Clinical Research Through Person-Fit Statistics: Examples and a Computer Program. *Assessment*, 23(1), 52–62.
- Miyamoto, Y. R., Coleman, C. A., Williams, J. J., Whitehill, J., Nesterko, S., & Reich, J. (2015). Beyond Time-on-Task: The Relationship Between Spaced Study and Certification in MOOCs. *Journal of Learning Analytics*, 2(2), 47–69.
- Molnar, C. (2019). *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. Dostupné z <https://christophm.github.io/interpretable-ml-book/>
- Monllaó Olivé, D., Huynh, D. Q., Reynolds, M., Dougiamas, M., & Wiese, D. (2019). A Quest for a One-Size-Fits-All Neural Network: Early Prediction of Students at Risk in Online Courses. *IEEE Transactions on Learning Technologies*, 12(2), 171–183.
- Moore, G. E. (1965). Cramming more components onto integrated circuits. *Electronics*, 38(8), 114–117.
- Moore, M. G. (1989). Editorial: Three types of interaction. *American Journal of Distance Education*, 3(2), 1–7.
- Mostow, J., Beck, J., Cuneo, A., Gouvea, E., & Heiner, C. (2005). A Generic Tool to Browse TutorStudent Interactions: Time Will Tell! In *Proceedings of the 12th International Conference on Artificial Intelligence in Education*, (s. 884–886). Amsterdam.
- Muldner, K., Burleson, W., Van de Sande, B., & VanLehn, K. (2011). An analysis of students' gaming behaviors in an intelligent tutoring system: predictors and impacts. *User Modeling and User-Adapted Interaction*, 21(1–2), 99–135.
- Nakayama, M., Mutsuura, K., & Yamamoto, H. (2017). The possibility of predicting learning performance using features of note taking activities and instructions in a blended learning environment. *International Journal of Educational Technology in Higher Education*, 14(6), 1–14.
- Nandi, D., Hamilton, M., & Harland, J. (2012). Evaluating the quality of interaction in asynchronous discussion forums in fully online courses. *Distance Education*, 33(1), 5–30.
- Naur, P. (1974). *Concise Survey of Computer Methods*. Lund: Studentlitteratur.
- Nezvalová, D. (2003). Akční výzkum ve škole. *Pedagogika*, 53(3), 300–308.



- Ocuppaugh, J., Baker, R. S., Gowda, S., Heffernan, H., & Heffernan, C. (2014). Population validity for educational data mining models: A case study in affect detection. *British Journal of Educational Technology*, 45(3), 487–501.
- Ochoa, X. (2017). Multimodal Learning Analytics. In C. Lang, G. Siemens, A. Wise, & D. Gašević (Eds.), *Handbook of Learning Analytics* (s. 129–141). Society for Learning Analytics Research.
- O'Neil, C., & Schutt, R. (2013). *Doing Data Science: Straight Talk from the Frontline*. Sebastopol, CA: O'Reilly Media.
- Pabian, P. (2012). Jak se učí na vysokých školách: výzkumný směr „přístupů k učení“. *Aula*, 20(1), 48–77.
- Papamitsiou, Z., & Economides, A. A. (2014). Learning Analytics and Educational Data Mining in Practice: A Systematic Literature Review of Empirical Evidence. *Educational Technology & Society*, 17(4), 49–64.
- Papamitsiou, Z., & Economides, A. A. (2016). Process Mining of Interactions During Computer-Based Testing for Detecting and Modelling Guessing Behavior. In P. Zaphiris, & A. Ioannou (Ed.), *Learning and Collaboration Technologies: Third International Conference, LCT 2016, Held as Part of HCI International 2016, Toronto, ON, Canada, July 17-22, 2016, Proceedings*. Springer International Publishing.
- Papoušek, J., Stanislav, V., & Pelánek, R. (2016). Evaluation of an adaptive practice system for learning geography facts. In *Proceedings of the Sixth International Conference on Learning Analytics & Knowledge* (s. 134–142). Edinburgh: ACM.
- Pardo, A., & Siemens, G. (2014). Ethical and privacy principles for learning analytics. *British Journal of Educational Technology*, 45(3), 438–450.
- Pariser, E. (2011). *The filter bubble: What the Internet is hiding from you*. New York: Penguin Press.
- Peat, M., & Franklin, S. (2002). Supporting student learning: the use of computer-based formative assessment modules. *British Journal of Educational Technology*, 33(5), 515–523.
- Pedagogy*. (2018). Moodle Docs. Dostupné z <https://docs.moodle.org/en/Pedagogy>
- Pechenizkiy, M., Trčka, N., Vasilyeva, E., van der Aalst, W., & De Bra, P. (2009). Process mining online assessment data. In T. Barnes, M. Desmarais, C. Romero, & S. Ventura (Eds.), *Educational Data Mining 2009: 2nd International Conference on Educational Data Mining: proceedings [EDM'09]*. Cordoba, Spain: International Educational Data Mining Society.

- Pekrun, R., & Stephens, E. J. (2012). Academic emotions. In K. R. Harris, S. Graham, T. Urdan, S. Graham, J. M. Royer, & M. Zeidner, *APA educational psychology handbook, Vol 2: Individual differences and cultural and contextual factors* (s. 3–31). Washington, DC: American Psychological Association.
- Pelánek, R. (2016). Applications of the Elo rating system in adaptive educational systems. *Computers & Education, 98*, 169–179.
- Pelánek, R. (2017). Bayesian knowledge tracing, logistic models, and beyond: an overview of learner modeling techniques. *User Modeling and User-Adapted Interaction, 27*(3–5), 313–350.
- Peña-Ayala, A. (Ed.). (2014a). *Educational Data Mining: Applications and Trends*. New York: Springer.
- Peña-Ayala, A. (2014b). Educational data mining: A survey and a data mining-based analysis of recent works. *Expert Systems with Applications, 41*, 1432–1462.
- Peña-Ayala, A. (Ed.). (2017). *Learning Analytics: Fundamentals, Applications, and Trends: A View of the Current State of the Art to Enhance e-Learning*. New York: Springer.
- Peña-Ayala, A. (2018). Learning analytics: A glance of evolution, status, and trends according to a proposed taxonomy. *WIREs Data Mining and Knowledge Discovery, 1–29*.
- Phillips, R., Maor, D., Cumming-Potvin, W., Roberts, P., Herrington, J., Preston, G., . . . Perry, L. (2011). Learning analytics and study behaviour: A pilot study. *Changing Demands, Changing Directions* (s. 997–1007). Hobart: University of Tasmania.
- Philosophy. (2018). Moodle Docs. Dostupné z <https://docs.moodle.org/en/Philosophy>
- Picciano, A. G. (2012). The Evolution of Big Data and Learning Analytics in American Higher Education. *Journal of Asynchronous Learning Networks, 16*(3), 9–20.
- Pintrich, P. R. (2004). A Conceptual Framework for Assessing Motivation and Self-Regulated Learning in College Students. *Educational Psychology Review, 16*(4), 385–407.
- Pintrich, P. R., Smith, D. A., Garcia, T., & McKeachie, W. J. (1993). Reliability and predictive validity of the Motivated Strategies for Learning Questionnaire (MSLQ). *Educational and Psychological Measurement, 53*(3), 801–813.
- Poláčková Šolcová, I., & Trnka, R. (2015). Příspěvek k teorii afektivních procesů. *Československá psychologie, 59*(4), 298–314.
- Popper, K. R. (1997). *Logika vědeckého výzkumu*. Praha: OIKOYMENH.
- Poulová, P. (2010). Uplatnění elearningu na českých univerzitách – desetiletá historie. In L. Rohlíková, & J. Beseda (Ed.), *Sborník příspěvků 6. mezinárodní konference*

- o distančním vzdělávání DisCo 2010* (s. 32–36). Plzeň: Západočeská univerzita v Plzni.
- Prinsloo, P., & Slade, S. (2017). Ethics and Learning Analytics: Charting the (Un)Charted. In C. Lang, G. Siemens, A. Wise, & D. Gašević (Eds.), *Handbook of Learning Analytics* (s. 49–57). Society for Learning Analytics Research.
- Průcha, J. (2000). *Přehled pedagogiky*. Praha: Portál.
- Průcha, J. (2005). *Moderní pedagogika*. Praha: Portál.
- Průcha, J., & Švaříček, R. (2009). Etický kodex české pedagogické vědy a výzkumu. *Pedagogická orientace*, 19(2), 89–105.
- Průcha, J., Walterová, E., & Mareš, J. (2003). *Pedagogický slovník*. Praha: Portál.
- Průcha, J., Walterová, E., & Mareš, J. (2009). *Pedagogický slovník*. Praha: Portál.
- R Core Team. (2018). *R: A Language and Environment for Statistical Computing*. Vienna, Austria: R Foundation for Statistical Computing. Dostupné z <https://www.R-project.org/>
- Rabbany, R., ElAtia, S., Takaffoli, M., & Zaïane, O. R. (2014). Collaborative learning of students in online discussion forums: A social network analysis perspective. In A. Peña-Ayala (Ed.), *Educational data mining: Applications and trends* (s. 441–466). Cham: Springer.
- Raca, M., & Dillenbourg, P. (2013). System for assessing classroom attention. In *Proceedings of the Third International Conference on Learning Analytics and Knowledge* (s. 265–269). New York: ACM.
- Raca, M., Tormey, R., & Dillenbourg, P. (2014). Sleepers' lag: Study on motion and attention. In *Proceedings of the Fourth International Conference on Learning Analytics And Knowledge* (s. 36–43). New York: ACM.
- Rambousek, J. (2004). Poznámky k e-learningu na vysokých školách. In J. Rambousek, & D. Mikšík (Eds.), *E learning přichází* (s. 29–34). Brno: Masarykova univerzita.
- Rambousek, J., Pytela, Z., & Mikšík, D. (2005). *Historie e-learningu na MU*. Dostupné z [http://www.phil.muni.cz/elearning/historie\\_elmu.php](http://www.phil.muni.cz/elearning/historie_elmu.php)
- Rathouz, V. (2017). *Vybrané kapitoly z umělé inteligence ve vzdělávání*. Brno: Flow.
- Reimann, P., & Yacef, K. (2013). Using process mining for understanding learning. In R. Luckin, S. Puntambekar, P. Goodyear, B. Grabowski, J. Underwood, & N. Winters (Eds.), *Handbook of design in educational technology*. New York: Routledge.
- Reimann, P., Markauskaite, L., & Bannert, M. (2014). e-Research and learning theory: What do sequence and process mining methods contribute? *British Journal of Educational Technology*, 45(3), 528–540.

- Rivera, W., Goel, A., & Kincaid, J. P. (2016). Advances in Algorithms for Re-Sampling Class-Imbalanced Educational Data Sets. In M. Anderson, & C. Gavan (Eds.), *Developing Effective Educational Experiences through Learning Analytics*. Hershey, PA: IGI Global.
- Roadmap. (2019). Retrieved 30. 5. 2019, from Dev docs:  
<https://docs.moodle.org/dev/Roadmap>
- Romero, C., & Ventura, S. (Eds.). (2005). *Data Mining in E-Learning*. Southampton: WIT Press.
- Romero, C., & Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33(1), 135–146.
- Romero, C., & Ventura, S. (2010). Educational Data Mining: A Review of the State of the Art. *IEEE Transactions on Systems, Man, and Cybernetics—Part C: Applications and Reviews*, 40(6), 601–618.
- Romero, C., & Ventura, S. (2013). Data mining in education. *WIREs Data Mining and Knowledge Discovery*, 3, 12–27.
- Romero, C., & Ventura, S. (2019). Guest Editorial: Special Issue on Early Prediction and Supporting of Learning Performance. *IEEE Transactions on Learning Technologies*, 12(2), 145–147.
- Romero, C., Cerezo, R., Bogarín, A., & Sánchez-Santillán, M. (2016). Educational process mining: A tutorial and case study using moodle data sets. In S. ElAtia, D. Ipperciel, & O. R. Zaïane (Eds.), *Data Mining and Learning Analytics: Applications in Educational Research* (s. 3–28). Hoboken, New Jersey: John Wiley & Sons.
- Romero, C., Espejo, P. G., Zafra, A., Romero, J. R., & Ventura, S. (2013). Web Usage Mining for Predicting Final Marks of Students That Use Moodle Courses. *Computer Applications in Engineering Education*, 21(1), 135–146.
- Romero, C., López, M.-I., Luna, J.-M., & Ventura, S. (2013). Predicting students' final performance from participation in on-line discussion forums. *Computers & Education*(68), 458–472.
- Romero, C., Ventura, S., & García, E. (2008). Data mining in course management systems: Moodle case study and tutorial. *Computers & Education*, 51(1), 368–384.
- Romero, C., Ventura, S., Pechenizkiy, M., & Baker, R. S. (Eds.). (2010). *Handbook of Educational Data Mining*. Boca Raton, FL: CRC Press.
- Rosé, C. P. (2017). Discourse Analytics. In C. Lang, G. Siemens, A. Wise, & D. & Gašević (Eds.), *Handbook of Learning Analytics* (s. 105–114). Society for Learning Analytics Research.

- RStudio Team. (2016). *RStudio: Integrated Development Environment for R*. Boston, MA: RStudio, Inc. Dostupné z <http://www.rstudio.com/>
- Rupp, A. A. (2013). A systematic review of the methodology for person fit research in Item Response Theory: Lessons about generalizability of inferences from the design of simulation studies. *Psychological Test and Assessment Modeling*, 55(1), 3–38.
- Sani, S. M., Bichi, A. B., & Ayuba, S. (2016). Artificial Intelligence Approaches in Student Modeling: Half Decade Review (2010-2015). *International Journal of Computer Science and Network*, 5(5), 746–754.
- Saqr, M., Fors, U., & Nouri, J. (2018). Using social network analysis to understand online Problem-Based Learning and predict performance. *PLoS ONE*, 13(9), 1–20.
- Slater, N. (2014). *Code of practice for learning analytics: A literature review of the ethical and legal issues*. Jisc. Dostupné z [http://repository.jisc.ac.uk/5661/1/Learning\\_Analytics\\_A\\_-\\_Literature\\_Review.pdf](http://repository.jisc.ac.uk/5661/1/Learning_Analytics_A_-_Literature_Review.pdf)
- Slater, N. (2016). Developing a Code of Practice for Learning Analytics. *Journal of Learning Analytics*, 3(1), 16–42.
- Slater, N. (2017). *Learning Analytics Explained*. New York: Routledge.
- Scott, J., & Carrington, P. J. (Eds.). (2011). *The SAGE Handbook of Social Network Analysis*. London: SAGE.
- Şen, B., Uçar, E., & Denle, D. (2012). Predicting and analyzing secondary education placement-test scores: a data mining approach. *Expert Systems with Applications*, 39(10), 9468–9476.
- Sheshadri, A., Gitinabard, N., Lynch, C. F., Barnes, T., & Heckman, S. (2018). Predicting Student Performance Based on Online Study Habits: A Study of Blended Courses. In K. E. Boyer, & M. Yudelson (Eds.), *Proceedings of the 11th International Conference on Educational Data Mining* (s. 411–417). Buffalo, NY: International Educational Data Mining Society.
- Schmid, J., & Šubrt, J. (2010). Analýza sociálních sítí. In J. Šubrt, *Soudobá sociologie IV. Aktuální a každodenní* (s. 332–363). Praha: Karolinum.
- Schoor, C., & Bannert, M. (2012). Exploring regulatory processes during a computer-supported collaborative learning task using process mining. *Computers in Human Behavior*, 28(4), 1321–1331.
- Schreurs, B., & De Laat, M. (2012). Network Awareness Tool – Learning Analytics in the workplace: Detecting and Analyzing Informal Workplace Learning. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (s. 59–64). New York: ACM Press.

- Schwendimann, B. A., Rodriguez-Triana, M. J., Vozniuk, A., Prieto, L. P., Boroujeni, M. S., Holzer, A., . . . Dillenbourg, P. (2017). Perceiving Learning at a Glance: A Systematic Literature Review of Learning Dashboard Research. *IEEE Transactions on Learning Technologies*, *10*(1), 30–41.
- Siemens, G. (2012). Learning analytics: envisioning a research discipline and a domain of practice. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (s. 4–8). New York: ACM.
- Siemens, G. (2013). Learning Analytics: The Emergence of a Discipline. *American Behavioral Scientist*, *57*(10), 1380–1400.
- Siemens, G., & Baker, R. S. (2012). Learning analytics and educational data mining: towards communication and collaboration. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (s. 252–254). Vancouver, British Columbia, Canada: ACM.
- Sing, T., Sander, O., Beerenwinkel, N., & Lengauer, T. (2005). ROCr: visualizing classifier performance in R. *Bioinformatics*, *21*(20), 78–81.
- Slade, S., & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. *American Behavioral Scientist*, *57*(10), 1510–1529.
- Slim, G., Must, O., & Täht, K. (2013). Test-taking effort as a predictor of performance in low-stakes tests. *Trames*, *17*(4), 433–448.
- Smith, V. C., Lange, A., & Huston, D. R. (2012). Predictive Modeling to Forecast Student Outcomes and Drive Effective Interventions in Online Community College Courses. *Journal of Asynchronous Learning Networks*, *16*(3), 51–61.
- Soukup, P. (2006). Proč užívat hierarchické lineární modely? *Sociologický časopis/Czech Sociological Review*, *42*(5), 987–1012.
- Soukup, P. (2016). Možnosti praktické práce s daty z mezinárodních vzdělávacích studií: Problémy a jejich praktická řešení. *Orbis Scholae*, *10*(1), 97–120.
- Speiser, J. L., Wolf, B. J., Chung, D., Karvellas, C. J., Koch, D. G., & Durkalski, V. L. (2018). BiMM tree: a decision tree method for modeling clustered and longitudinal binary outcomes. *Communications in Statistics - Simulation and Computation*. doi:10.1080/03610918.2018.1490429
- Stepanyan, K., Mather, R., & Dalrymple, R. (2014). Culture, role and group work: A social network analysis perspective on an online collaborative course. *British Journal of Educational Technology*, *45*(4), 676–693.
- Straková, J. (2016). *Mezinárodní výzkumy výsledků vzdělávání: Metodologie, přínosy, rizika a příležitosti*. Praha: Univerzita Karlova v Praze, Pedagogická fakulta.

- Švaříček, R., & Šedřová, K. (2007). *Kvalitativní výzkum v pedagogických vědách*. Praha: Portál.
- Švaříček, R., & Zounek, J. (2008). E-learning ve vysokoškolské výuce pohledem empirického výzkumu. *Studia paedagogica*, 13, 101–126.
- Terzis, V., & Economides, A. A. (2011). The acceptance and use of computer based assessment. *Computers & Education*, 56(4), 1032–1044.
- Therneau, T., & Atkinson, B. (2018). *rpart: Recursive Partitioning and Regression Trees*. Dostupné z <https://CRAN.R-project.org/package=rpart>
- Thomas, J. (2013). Exploring the use of asynchronous online discussion in health care education: A literature review. *Computers & Education*, 69, 199–215.
- Thompson, M. M. (2007). From distance education to E-learning. In R. Andrews, & C. Haythornthwaite (Eds.), *The SAGE Handbook of E-learning Research* (s. 159–178). London: SAGE Publications.
- Tirado, R., Hernando, Á., & Aguaded, J. I. (2015). The effect of centralization and cohesion on the social construction of knowledge in discussion forums. *Interactive Learning Environments*, 23(3), 293–316.
- Tirado-Morueta, R., Maraver-López, P., & Hernando-Gómez, Á. (2017). Patterns of Participation and Social Connections in Online Discussion Forums. *Small Group Research*, 48(6), 639–664.
- Trčka, N., Pechenizkiy, M., & van der Aalst, W. (2010). Process mining from educational data. In C. Romero, S. Ventura, M. Pechenizkiy, & R. S. Baker (Eds.), *Handbook of educational data mining*. Boca Raton: CRC Press.
- Tukey, J. W. (1962). The Future of Data Analysis. *The Annals of Mathematical Statistics*, 33(1), 1–67.
- Tukey, J. W. (1977). *Exploratory data analysis*. Reading, Massachusetts: Addison-Wesley Publishing.
- Turing, A. (1950). Computing Machinery and Intelligence. *Mind*, 59(236), 433–460.
- Urbánek, T., Denglerová, D., & Širůček, J. (2011). *Psychometrika: měření v psychologii*. Praha: Portál.
- Vaculíková, J. (2018). Measuring Self-regulated Learning and Online Learning Events to Predict Student Academic Performance. *Studia paedagogica*, 23(4), 91–118.
- Van Barneveld, A., Arnold, K. E., & Campbell, J. P. (2012). *Analytics in higher education: Establishing a common language*. Educause Learning Initiative. Dostupné z <http://www.educause.edu/library/resources/analytics-higher-education-establishing-common-language>

- van der Aalst, W. (2011). *Process Mining: Discovery, Conformance and Enhancement of Business Processes*. New York: Springer.
- van der Aalst, W. (2016). *Process Mining: Data Science in Action*. Springer: New York.
- van der Aalst, W., Guo, S., & Gorissen, P. (2013). Comparative Process Mining in Education: An Approach Based on Process Cubes. In P. Ceravolo, R. Accorsi, & P. Cudre-Mauroux (Ed.), *Data-Driven Process Discovery and Analysis: Third IFIP WG 2.6, 2.12 International Symposium, SIMPDA 2013, Riva del Garda, Italy, August 30, 2013, Revised Selected Papers*. New York: Springer.
- van Dongen, B. F., de Medeiros, A. K., Verbeek, H. M., Weijters, A. J., & van der Aalst, W. M. (2005). The ProM Framework: A New Era in Process Mining Tool Support. In G. Ciardo, & P. Darondeau (Eds.), *Applications and Theory of Petri Nets 2005* (s. 444–454). Berlin: Springer.
- Vie, J. J., Popineau, F., Bruillard, É., & Bourda, Y. (2017). A Review of Recent Advances in Adaptive Assessment. In Peña-Ayala, & A. (Eds.), *Learning Analytics: Fundamentals, Applications, and Trends* (s. 113–142). Cham: Springer.
- Wasserman, S., & Faust, K. (1994). *Social Network Analysis: Methods and Applications*. Cambridge University Press.
- Weller, M. (2007). *Virtual Learning Environments: Using, choosing and developing your VLE*. New York: Routledge.
- Wen, M., Yang, D., & Rosé, C. P. (2014). Sentiment Analysis in MOOC Discussion Forums: What does it tell us?. In J. Stamper, Z. Pardos, M. Mavrikis, & B. M. McLaren (Ed.), *Proceedings of the 7th International Conference on Educational Data Mining* (s. 130–137). London: International Educational Data Mining Society.
- Whitelock, D. (2006). Electronic assessment: marking, monitoring and mediating learning. *International Journal of Learning Technology*, 2(2–3), 264–276.
- Whitelock, D., Twiner, A., Richardson, J. T., Field, D., & Pulman, S. (2015). OpenEssayist: a supply and demand learning analytics tool for drafting academic essays. In *Proceedings of the Fifth International Conference on Learning Analytics And Knowledge* (s. 208–212). New York: ACM Press.
- Williamson, B. (2017). *Big Data in Education: The digital future of learning, policy and practice*. London: SAGE.
- Willis III, J. E., Slade, S., & Prinsloo, P. (2016). Ethical oversight of student data in learning analytics: a typology derived from a cross-continental, cross-institutional perspective. *Educational Technology Research and Development*, 64(5), 881–901.



- Winne, P. H. (2010). Improving measurements of self-regulated learning. *Educational Psychologist, 45*(4), 267–276.
- Wise, A. F., & Cui, Y. (2018). Learning communities in the crowd: Characteristics of content related interactions and social relationships in MOOC discussion forums. *Computers & Education, 122*, 221–242.
- Wise, A. F., & Paulus, T. M. (2016). Analyzing Learning in Online Discussions. In C. Haythornthwaite, R. Andrews, J. Fransman, & E. M. Meyers (Eds.), *The SAGE Handbook of E-learning Research* (2. ed., 270–290). London: SAGE Publications.
- Wise, A. F., & Shaffer, D. W. (2015). Why Theory Matters More than Ever in the Age of Big Data. *Journal of Learning Analytics, 2*(2), 5–13.
- Wise, A. F., & Vytasek, J. (2017). Learning Analytics Implementation Design. In C. Lang, G. Siemens, A. Wise, & D. Gašević (Eds.), *Handbook of Learning Analytics* (s. 151–160). Society for Learning Analytics Research.
- Wise, A. F., Hausknecht, S. N., & Zhao, Y. (2014). Attending to others' posts in asynchronous discussions: Learners' online "listening" and its relationship to speaking. *International Journal of Computer-Supported Collaborative Learning, 9*(2), 185–209.
- Wise, S. L., & Kong, X. (2005). Response Time Effort: A New Measure of Examinee Motivation in Computer-Based Tests. *Applied Measurement in Education, 18*(2), 163–183.
- Wise, S. L., Pastor, D. A., & Kong, X. (2009). Correlates of Rapid-Guessing Behavior in Low-Stakes Testing: Implications for Test Development and Measurement Practice. *Applied Measurement in Education, 22*, 185–205.
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques* (3. ed.). Morgan Kaufmann.
- Worsley, M. (2018). Multimodal Learning Analytics' Past, Present, and, Potential Futures. In A. Pardo, K. Bartimote, G. Lynch, S. Buckingham Shum, R. Ferguson, A. Merceron, & X. Ochoa (Ed.), *Companion Proceedings of the 8th International Conference on Learning Analytics & Knowledge (LAK'18)* (s. 404–419). Sydney, Australia: Society for Learning Analytics Research.
- Xie, K., Di Tosto, G., Lu, L., & Cho, Y. S. (2018). Detecting leadership in peer-moderated online collaborative learning through text mining and social network analysis. *The Internet and Higher Education, 38*, 9–17.
- Yang, D., Kraut, R. E., & Rosé, C. P. (2016). Exploring the Effect of Student Confusion in Massive Open Online Courses. *Journal of Educational Data Mining, 8*(1), 52–83.

- You, J. W. (2016). Identifying significant indicators using LMS data to predict course achievement in online learning. *Internet and Higher Education*, 29, 23–30.
- Youden, W. J. (1950). Index for rating diagnostic tests. *Cancer*, 3(1), 32–35.
- Yu, T., & Jo, I.-H. (2014). Educational Technology Approach toward Learning Analytics: Relationship between Student Online Behavior and Learning Performance in Higher Education. In *Proceedings of the Fourth International Conference on Learning Analytics And Knowledge* (s. 269–270). Indianapolis: ACM.
- Zafra, A., Romero, C., & Ventura, S. (2011). Multiple instance learning for classifying students in learning management systems. *Expert Systems with Applications*, 38, 15020–15031.
- Zhang, J., Skryabin, M., & Song, X. (2016). Understanding the dynamics of MOOC discussion forums with simulation investigation for empirical network analysis (SIENA). *Distance Education*, 37(3), 270–286.
- Zhang, N., & Henderson, C. N. (2015). Can formative quizzes predict or improve summative exam performance?. *The Journal of Chiropractic Education*, 29(1), 16–21.
- Zimmerman, B., & Martinez-Pons, M. (1988). Construct validation of a strategy model of student self-regulated learning. *Journal of Educational Psychology*, 80(3), 284–290.
- Zounek, J. (2009). *E-learning – jedna z podob učení v moderní společnosti*. Brno: Masarykova univerzita.
- Zounek, J., & Sudický, P. (2012). *E-learning: učení (se) s online technologiemi*. Praha: Wolters Kluwer.
- Zounek, J., & Tůma, F. (2014). Problematika ICT ve vzdělávání v českých pedagogických časopisech (1990–2012). *Studia paedagogica*, 19(3), 65–87.
- Zounek, J., Juhaňák, L., Staudková, H., & Poláček, J. (2016). *E-learning. Učení (se) s digitálními technologiemi*. Praha: Wolters Kluwer.
- Žitný, P. (2014). *Aplikácia teórie odpovede na položku v psychometrickej analýze a počítačovom adaptívnom testovaní*. Trnava: Filozofická fakulta Trnavskej univerzity v Trnave .