

MUNI
MED

MIAM021p(s) Analýza a management dat pro zdravotnické obory – přednáška a cvičení (jaro 2023)

MICHAL SVOBODA

Institut biostatistiky a analýz LF MU
svoboda@iba.muni.cz

Osnova

- Excel: opakování, příprava dat, základní vzorce
- Základy popisné statistiky
- Základní rozdělení pravděpodobnosti, testování hypotéz
- Parametrické testy
- Neparametrické testy
- Analýza kontingenčních tabulek
- Základy korelační analýzy a lineární regrese

Důležité informace

- Výuka: 11:00–13:30, D29/347-RCX2
- Materiály v IS
- Software: Microsoft Office - Excel, Statistica
- Pro získání zápočtu/kolokvia je třeba:
 - 1. Účast – povoleny jsou 2 absence**
 - 2. Domácí úkoly – povoleno 1 neodevzdání**
 - za účelem procvičení, dostanete zpětnou vazbu, na dalším cvičení se vrátíme, kdyby byl problém
 - 3. Závěrečný úkol** – praktické úkoly (povoleny materiály)

Organizace výuky

- 21. 2. – Excel: opakování, příprava dat, základní vzorce
- 28. 2. – Základy popisné statistiky
- 7. 3. – Základní rozdělení pravděpodobnosti, testování hypotéz
- 14. 3. – Parametrické testy
- 21. 3. – Neparametrické testy
- 28. 3. – Analýza kontingenčních tabulek, testy dobré shody
- 4. 4. – Základy korelační analýzy + opakování vybraných témat
- 11. 4. – Volitelné sezení, návrat k vybraným tématům
- 18. 4. – Ukončení předmětu, test

Motivace

- Současná statistická analýza se neobejde bez zpracování dat pomocí statistických software. Předpokladem úspěchu je správné uložení dat ve formě „databázové“ tabulky umožňující jejich zpracování v libovolné aplikaci.
- Neméně důležité je věnovat pozornost čištění dat předcházející vlastní analýze. Každá chyba, která vznikne nebo není nalezena ve fázi přípravy dat se promítne do všech dalších kroků a může zapříčinit neplatnost výsledků a nutnost opakování analýzy.

Příprava dat, MS Excel

Datová tabulka

Zásady správné tvorby dat

Možnosti MS Excel

Ukázka datového souboru

Parametry (znaky)

Základní jednotka dat!

	A	AC	AD	AE	AF	AG	AH	AI	AJ
1	ID	obvod_pasu_po	obvod_boku_po	WHR_po	WHR_riziko_po	syst_tlak_po	diast_tlak_po	hypertenze_po	cholesterol_po
2	1	86,7	98,6	0,88	1	103	68	0	3,82
3	2	70,3	82,9	0,85	1	118	75	0	6,18
4	3	61,2	88,3	0,69	1	114	74	0	3,90
5	4	81,6	87,3	0,93	1	127	73	0	5,06
6	5	89,2	104,2	0,86	3	135	99	1	6,24
7	6	74,2	100,1	0,74	1	111	81	0	3,44
8	7	114,2	108,5	1,05	3	136	80	0	4,17
9	8	65,1	82,5	0,79	1	118	98	1	2,87
10	9	81,5	79,0	1,03	3	116	87	0	4,20
11	10	75,9	124,9	0,61	1	125	82	0	4,12
12	11	89,8	111,6	0,80	2	108	84	0	2,83
13	12	67,8	87,9	0,77	1	120	64	0	4,71
14	13	95,7	92,7	1,03	3	169	112	1	4,67
15	14	86,1	88,5	0,97	2	111	82	0	4,91
16	15	86,4	101,2	0,85	1	108	79	0	4,99
17	16	68,1	86,3	0,79	1	122	81	0	4,83
18	17	65,0	77,9	0,83	1	139	81	0	4,17
19	18	92,5	72,8	1,27	3	143	77	1	5,89
20	19	69,4	81,6	0,85	2	130	90	0	5,90
21	20	93,7	90,8	1,03	3	136	83	0	4,64
22	21	71,4	83,5	0,86	3	123	83	0	4,75
23	22	95,0	95,4	1,00	3	141	91	1	4,18

Zásady pro ukládání dat


- Správné a přehledné uložení dat je základem jejich pozdější analýzy.
- Je vhodné rozmyslet si předem jak budou data ukládána.
- Pro počítačové zpracování dat je nezbytné ukládat data v tabulární formě.
- Nejvhodnějším způsobem je uložení dat ve formě databázové tabulky.
- Takto uspořádaná data je v tabulkových nebo databázových programech možné převést na libovolnou výstupní tabulku.
- Pro základní uložení a čištění dat menšího rozsahu je možné využít aplikací MS Excel.

Zásady pro ukládání dat

- Každý **sloupec** obsahuje pouze **jediný typ dat**, identifikovaný hlavičkou sloupce;
- Každý **řádek** obsahuje **minimální jednotku dat** (např. pacient, jedna návštěva pacienta apod.);
- Je nepřípustné kombinovat v jednom sloupci číselné a textové hodnoty;
- Komentáře jsou uloženy v samostatných sloupcích;
- U textových dat je nezbytné kontrolovat překlepy v názvech kategorií;
- Specifickým typem dat jsou data, u nichž je nezbytné kontrolovat, zda jsou uloženy v korektním formátu.


MS Excel

- Tabulkový procesor.
- Aktualizace každé 2 až 3 roky; nové funkce, rozšíření počtu řádků a sloupců, změna formátu.
- Starší formát: .xls, novější: .xlsx.
- Aktuální verze 2016 umožňuje ukládat tabulku o 1 048 576 řádcích a 16 384 sloupcích.



Možnosti MS Excel

- Správa a práce s tabulárními daty.
- Řazení dat, výběry z dat, přehledy dat.
- Formátování a přehledné zobrazení dat.
- Zobrazení dat ve formě grafů.
- Různé druhy výpočtů pomocí zabudovaných funkcí.
- Tvorba tiskových sestav.
- Makra – zautomatizování častých činností.



16			
17	10	2	
18	12	3	
19	5	4	
20	8	5	
21	4	8	
22	7	9	
23	9	11	
24	suma součinů řádků		310
25			

P. biní	2				
Počet z Délka			Pohlaví		
Číslo	ryby2	Číslo	rvt	Váha	?
1					
2					
3					
4					
5					
6					
7	26				
8	106				
9	121				
10	160				
11	34				
12	45				
13	70				
14	72				
15	67				
16	Celkový součet				
17					

(Zobrazit vše)
 68
 99
 102
 109
 112
 120
 173
 28
 29

Import a export dat

Import dat

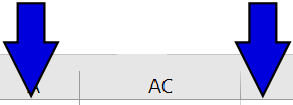
- Manuální zadávání
- Import – podpora importu ze starších verzí Excelu, textových souborů, databází apod.
- Kopírování přes schránku Windows – vkládání z nejrůznějších aplikací – MS Office, Statistica atd.

Export dat

- Ukládáním ve formátech podporovaných jinými SW, časté jsou textové soubory, dbf soubory nebo starší verze Excelu
- Přímé kopírování přes schránku Windows

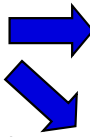
Databázová struktura dat v Excelu

Sloupce tabulky => parametry záznamů,
hlavička udává obsah sloupce – stejný údaj v celém sloupci



	AC	AD	AE	AF	AG	AH	AI	AJ	
1	ID	obvod_pasu_po	obvod_boku_po	WHR_po	WHR_riziko_po	syst_tlak_po	diast_tlak_po	hypertenze_po	cholesterol_po
2	1	86,7	98,6	0,88	1	103	68	0	3,82
3	2	70,3	82,9	0,85	1	118	75	0	6,18
4	3	61,2	88,3	0,69	1	114	74	0	3,90
5	4	81,6	87,3	0,93	1	127	73	0	5,06
6	5	89,2	104,2	0,86	3	135	99	1	6,24
7	6	74,2	100,1	0,74	1	111	81	0	3,44
8	7	114,2	108,5	1,05	3	136	80	0	4,17
9	8	65,1	82,5	0,79	1	118	98	1	2,87
10	9	81,5	79,0	1,03	3	116	87	0	4,20
11	10	75,9	124,9	0,61	1	125	82	0	4,12
12	11	89,8	111,6	0,80	2	108	84	0	2,83
13	12	67,8	87,9	0,77	1	120	64	0	4,71
14	13	95,7	92,7	1,03	3	169	112	1	4,67
15	14	86,1	88,5	0,97	2	111	82	0	4,91
16	15	86,4	101,2	0,85	1	108	79	0	4,99
17	16	68,1	86,3	0,79	1	122	81	0	4,83
18	17	65,0	77,9	0,83	1	139	81	0	4,17
19	18	92,5	72,8	1,27	3	143	77	1	5,89
20	19	69,4	81,6	0,85	2	130	90	0	5,90
21	20	93,7	90,8	1,03	3	136	83	0	4,64
22	21	71,4	83,5	0,86	3	123	83	0	4,75
23	22	95,0	95,4	1,00	3	141	91	1	4,18

Řádky tabulky =>
jednotlivé záznamy
(taxon, lokalita,
měření, pacient atd.)



Excel neumožňuje pojmenování řádků a sloupců vlastními názvy.

Typy a triky jak se v datech pohybovat

Výběr buněk

- CTRL+HOME – přesunutí na levý horní roh tabulky
- CTRL+END – přesunutí na pravý dolní roh tabulky
- CTRL+A – výběr celého listu
- CTRL + klepnutí myší do buňky – výběr jednotlivých buněk
- SHIFT + klepnutí myší na jinou buňku – výběr bloku buněk
- SHIFT + šipky – výběr sousedních buněk ve směru šipky
- SHIFT+CTRL+END (HOME) – výběr do konce (začátku) oblasti dat v listu
- SHIFT+CTRL+šipky – výběr souvislého řádku nebo sloupce buněk
- SHIFT + klepnutí na objekty – výběr více objektů

Kopírování a vkládání

- CTRL+C – zkopírování označené oblasti buněk
- CTRL+V – vložení obsahu schránky – oblast buněk, objekt, data z jiné aplikace

Myš a okraje buňky

- Chycení myší za okraj umožňuje přesun buňky nebo bloku buněk
- Při chycení čtverečku v pravém dolním rohu výběru je tažením možno vyplnit více buněk hodnotami původní buňky (ve vzorcích se mění relativní odkazy)

Ověření dat

- Nastavení pravidel, jaké hodnoty lze do jednotlivých sloupců
- **Nastavíme před zadáním prvního pacienta do dat**
- Zamezení překlepů v datech, kombinování více typů proměnných

1. Označení sloupce a zapnutí ověření dat




2. Nastavení možných hodnot pro daný sloupec (například hodnoty od 0 do 100)


Automatický filtr

- Pomocí automatického filtru je snadné vybírat úseky dat pro další zpracování na základě hodnot ve sloupcích databázové tabulky, výběr je možný i podle více sloupců (např. určitá skupina pacientů)
- Funkce automaticky rozezná hlavičky sloupců v souvislé oblasti buněk
- **Výhodné pro čištění dat (vyhledávání překlepů, kombinace textu a čísel)**

1. Zapnutí filtru (alternativa klávesová zkratka **Ctrl+Shift+L**)



Výběr hodnot pro filtraci



2. Objeví se rozbalovací šipka s výčtem všech unikátních hodnot v daném sloupci dat

The image shows an Excel table with columns A through E. A blue arrow points to the dropdown arrow in column B. The table contains the following data:

	A	B	C	D	E
1	ID	pohlaví	vek	vzdelai	vyska
2	1	0	55	1	182
3	2	0	56	2	169
4	3	1	59	3	169

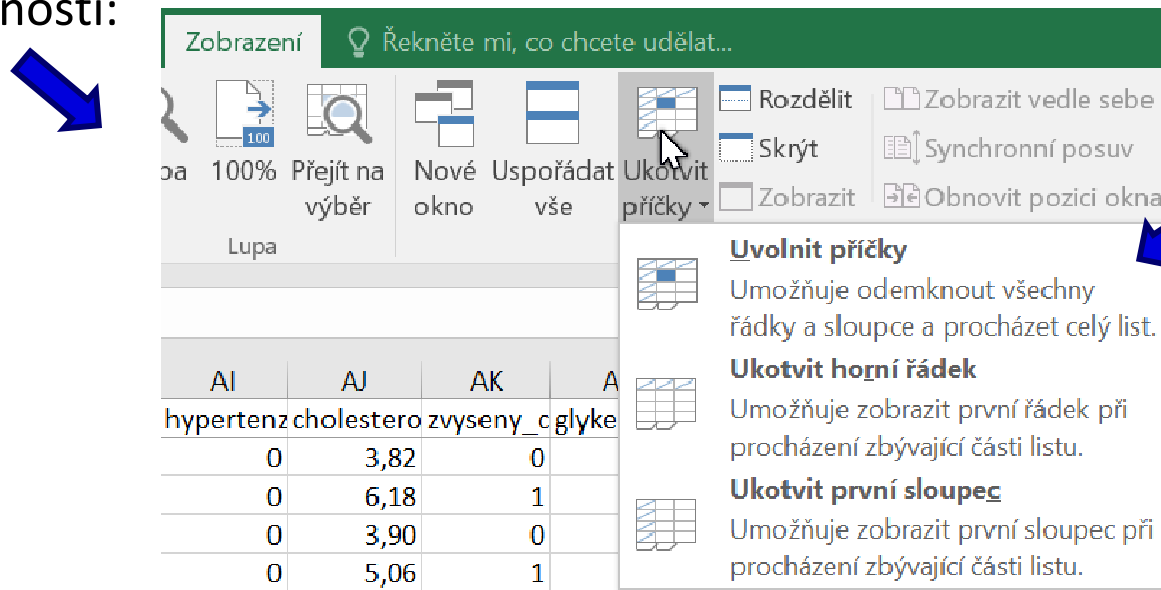
Podmíněné formátování

- Záložka „Domů“ → „Podmíněné formátování“.
- Barevné označení buněk nebo výplň buňky symbolem podle námi zadaných kritérií, např.:
 - numerická hodnota větší/menší než průměr
 - datum z konkrétního období
 - podobná slova
 - duplicitní údaje
- Co s barevnými buňkami?
- Použijeme filtr!

	123.0	320	2.35	41.1
0.45	129.0	218	2.36	48.5
	96.0	191	2.37	45.2

Ukotvení příček


- Umožňuje ukotvení libovolných řádků a sloupců pro pohodlné vkládání a prohlížení dat v tabulce.
- Umožňuje číst řádky/sloupce ze začátku tabulky i po přesunutí se dále.
- Záložka „Zobrazení“ → „Ukotvit příčky“.
- Odstranění ukotvení: Po ukotvení příček se automaticky možnost „Ukotvit příčky“ změní na „Uvolnit příčky“.
- Možnosti:



Ukotví řádky nad označenou buňkou a sloupce vlevo od označené buňky

Vzorce

- vpisují se do buněk sešitu
- vzorce jsou vždy uvozeny = (lze též + -)
- aritmetické operátory + zabudované funkce Excelu
- pro „sčítání“ nečíselných položek se používá &
- výpočet je založen buď na číselných konstantách nebo odkazech na buňky



Vzorce – odkaz na buňku

Relativní odkazy

- **A1** = buňka 1. řádku sloupci A
- **A1:B6** = blok buněk – levý horní roh je v 1. řádku, sloupec A, pravý dolní na řádku 6, sloupec B
- relativní odkaz se při automatickém vyplnění buněk vzorcem posune
- mění se s kopírováním, při vložení a odstranění řádku nebo sloupce


Absolutní odkaz

- odkaz na buňku je pevně dán, při kopírování nebo automatickém vyplnění se nemění
- lze uzamknout jak řádky, tak sloupce samostatně


uzamčení řádku → **\$A\$1** ← uzamčení sloupce

Pamatuj: Adresu upevníme pomocí znaku **\$** (klávesa **F4**)

Vzorce – využití seznamu vzorců

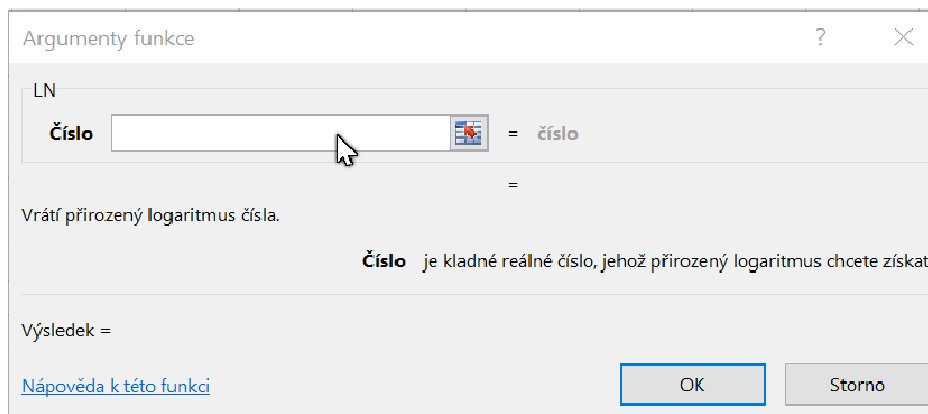


Kategorie vzorců



Funkce a její stručný popis

Průvodce funkcí



Vzorce – užitečné funkce

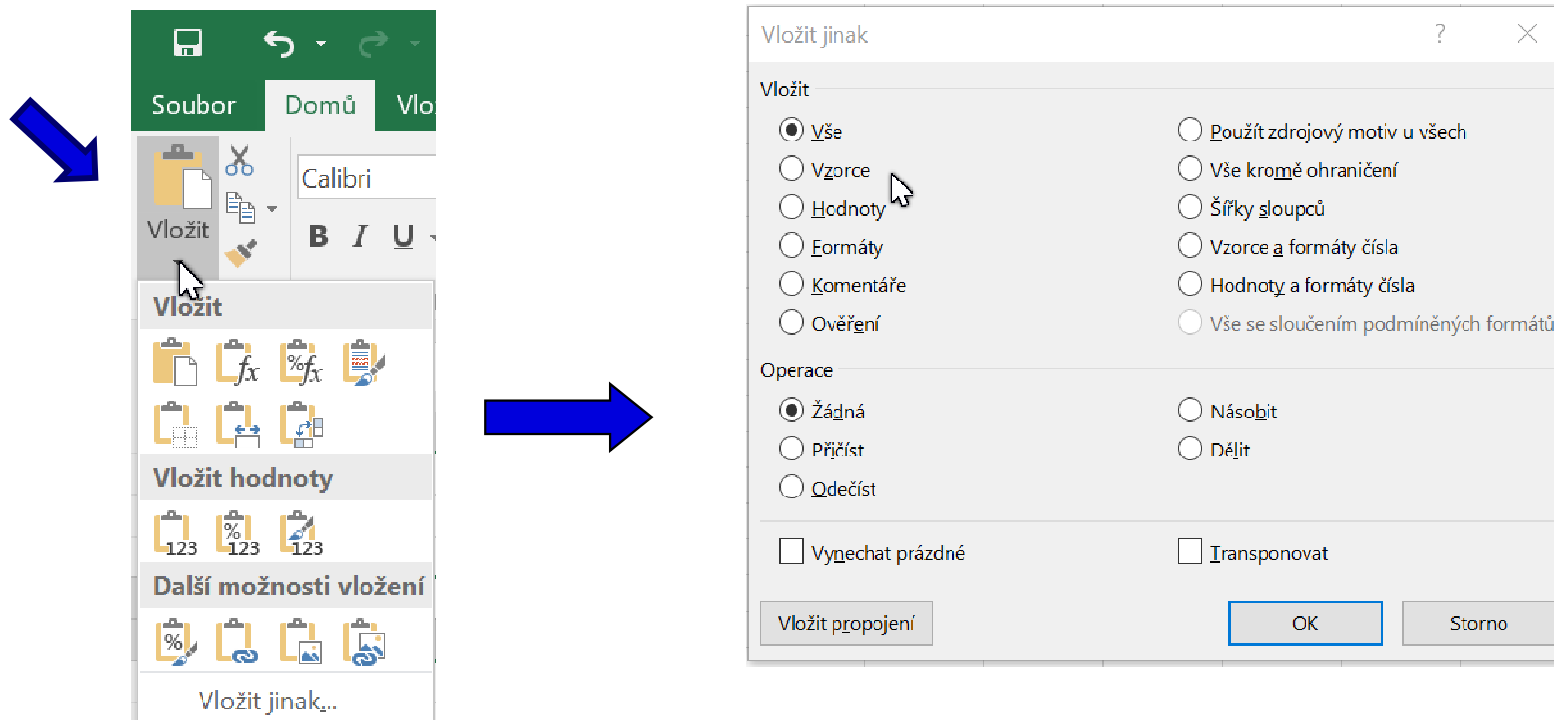
- **SUMA** – součet číselných hodnot oblasti;
- **SUMIF** – podmíněný součet (podmínky v doplňkové oblasti);
- **PRŮMĚR** – aritmetický průměr číselných hodnot oblasti;
- **GEOMEAN** – geometrický průměr číselných hodnot oblasti;
- **COUNTIF** – počet hodnot oblasti splňujících zadanou podmínku;
- **KDYŽ** – logická podmínka (IF);
- **MAX, MIN** – maximum/minimum číselných hodnot oblasti;
- **MEDIAN** – výpočet mediánu;
- **PERCENTIL** – výpočet percentilů;
- **DATUAM, ROK, MĚSÍC, DEN** – práce s kalendářními daty;
- **ABS** – absolutní hodnota;
- **SVYHLEDAT** – spojování tabulek podle identifikátoru - řádku.

Statistické funkce v MS Excel

- **CONFIDENCE.NORM** – výpočet intervalu spolehlivosti (při normálním rozdělení);
- **CORREL, PEARSON** – výpočet Pearsonova korelačního koeficientu;
- **COVARIANCE.S** – výpočet kovariance dvou množin dat;
- **COUNTIF** – počet hodnot oblasti splňujících zadanou podmínku;
- **DEVSQ** – součet čtverců odchylek od výběrového průměru;
- **F.DIST, GAMMA.DIST, T.DIST, NORM.DIST** aj. – různá rozdělení pravděpodobnosti;
- **PRŮMODCHYLKA** – průměrná hodnota absolutních odchylek;
- **SLOPE** – směrnice lineárního modelu;
- **T.TEST, Z.TEST, CHISQ.TEST** – statistické testy shodnosti;
- ŘADU DALŠÍCH FUNKCÍ VŠAK EXCEL POSTRÁDÁ A JE TŘEBA VYUŽÍT SILNĚJŠÍHO NÁSTROJE.

Kopírování a vkládání

- Kopírování vzorců, textů, celých sloupců (zkopírování pomocí Ctrl+C); dále „Vložit jinak...“



MUNI
MED

Praktické cvičení



Datový soubor

Rehabilitace po mozkovém infarktu

	A	B	C	D	E	F	G	H	
1	ID	Pohlaví	Věk	Etiologie	Lokalizace	Terapie	Komorbidity_k omplikace	Barthel_index_pr ed rehabilitaci	Katego red
2	1	muž	82	okluze nebo stenóza	mozkové tepny	jiná farmakologická terapie	0	25	vysoce
3	2	žena	81	embolie	mozkové tepny	jiná farmakologická terapie	2	20	vysoce
4	3	muž	55	okluze nebo stenóza	mozkové tepny	jiná farmakologická terapie	0	35	vysoce
5	4	žena	46	embolie	mozkové tepny	intravenózní trombolýza rt-PA	0	20	vysoce
6	5	muž	76	okluze nebo stenóza	mozkové tepny	jiná farmakologická terapie	0	45	částečn
7	6	muž	72	okluze nebo stenóza	mozkové tepny	jiná farmakologická terapie	0	25	vysoce
8	7	muž	62	trombóza	mozkové tepny	jiná farmakologická terapie	0	40	vysoce
9	8	muž	64	trombóza	přívodní tepny	jiná farmakologická terapie	0	15	vysoce
10	9	žena	82	okluze nebo stenóza	mozkové tepny	jiná farmakologická terapie	0	10	vysoce
11	10	muž	58	trombóza	mozkové tepny	jiná farmakologická terapie	0	25	vysoce
12	11	muž	84	okluze nebo stenóza	mozkové tepny	jiná farmakologická terapie	0	40	vysoce
13	12	žena	92	okluze nebo stenóza	mozkové tepny	jiná farmakologická terapie	0	30	vysoce
14	13	žena	79	embolie	mozkové tepny	jiná farmakologická terapie	1	40	vysoce
15	14	muž	69	trombóza	mozkové tepny	jiná farmakologická terapie	3	45	částečn
16	15	muž	67	okluze nebo stenóza	mozkové tepny	mechanická trombektomie	0	25	vysoce
17	16	žena	70	trombóza	přívodní tepny	mechanická trombektomie	0	40	vysoce
18	17	žena	59	trombóza	mozkové tepny	jiná farmakologická terapie	0	25	vysoce
19	18	žena	63	okluze nebo stenóza	přívodní tepny	jiná farmakologická terapie	0	40	vysoce

Rehabilitace po mozkovém infarktu

- Cvičný datový soubor obsahuje záznamy o **celkem 407 pacientech hospitalizovaných pro mozkový infarkt** na neurologickém oddělení akutní péče, kde jim byla poskytnuta terapie pro obnovu krevního oběhu v postižené části mozku.
- Po zvládnutí akutní fáze byl u pacientů vyhodnocen stupeň soběstačnosti v základních denních aktivitách (ADL) pomocí tzv. **indexu Barthelové (BI)** a byli přeloženi na **rehabilitační oddělení**.
- Po dvou týdnech byl opět dle BI vyhodnocen stupeň soběstačnosti a pacienti byli buď propuštěni do ambulantní péče, nebo přeloženi na oddělení následné péče.

Rehabilitace po mozkovém infarktu

Sbírané informace:

- základní demografické údaje (**pohlaví a věk**),
- informace o samotné diagnóze mozkové příhody (**etiologie a lokalizace uzávěru cévy**),
- informace o léčbě (typ indikované **terapie a výskyt komplikací**)
- informace o **způsobu ukončení rehabilitace**.
- Stupeň soběstačnosti před rehabilitací byl dodatečně zjištěn z neurologie a na konci rehabilitace byl vyplněn nový dotazník pro určení výsledného **indexu Barthelové**.

Úkol č. 1 – kontrola a příprava dat

1. Do všech řádků tabulky vyplňte do sloupce *Barthel_index_reference* hodnotu 64,4.
2. **Ukotvěte** ID pacientů a názvy proměnných ve sloupcích. (**nápověda**: vyber buňku pro levý horní roh → karta „Zobrazení“ → funkce Ukotvit příčky).
3. Zapněte **automatický filtr** nad celou datovou tabulkou a **zkontrolujte přítomnost chybných hodnot** ve sloupcích Pohlavi, Vek, Etiologie, Lokalizace, Terapie. Chybné hodnoty opravte. (**nápověda**: označ všechny sloupce → karta „Data“ → funkce Filtr).

Úkol č. 1 – kontrola a příprava dat

4. Pomocí **podmíněného formátování** nalezněte **duplicitní záznamy** ID pacientů. Jsou všechny Vámi označené záznamy skutečně duplicitní? Duplicitní údaj smažte. (**nápověda**: označ sloupec → karta „Domů“ → podmíněné formátování → zvýraznit pravidla buněk → duplicitní hodnoty → filtrovat podle barvy).
5. Spočítejte hodnoty ve sloupci *Barthel_index_po_rehabilitaci* jako celkový **součet** dosažených bodů v jednotlivých otázkách Barthelové testu po rehabilitaci. (**nápověda**: prostý součet jednotlivých buněk nebo funkce SUMA(...)).

Úkol č. 1 – kontrola a příprava dat

6. Spočítejte hodnoty ve sloupci *Barthel_index_zmena* jako **rozdíl** Barthelové indexu před a po rehabilitaci (**nápověda**: prostý vzorec pro rozdíl).
7. Sloupce *Barthel_index_pred_rehabilitaci* a *Barthel_index_po_rehabilitaci* **překódujte** do sloupců *Kategorie_zavislosti_pred_rehabilitaci* a *Kategorie_zavislosti_po_rehabilitaci* následovně: 0 až 40 = vysoce závislý, 45 až 100 = částečně soběstačný. (**nápověda**: pomocí funkce `KDYŽ(...)`).