Korpusová lingvistika – 1
Úvod – korpus a korpusová lingvistika, základní pojmy

Mgr. Dana Hlaváčková, Ph.D.

CJBB105

PRZA009

Organizace

- CJBB105 Korpusová lingvistika – přednáška
- PRZA009 Korpusová lingvistika
- Počítačová lingvistika, Český jazyk a literatura
- Překladatelství románských a germánských jazyků
- zakončení – zkouška – test, volné odpovědi
- přednáška, částečně praktické ukázky
- prezentace z přednášek ve studijních materiálech IS
- CJBB75 Základy využití korpusů (pro praxi)
- CJBB84 Morfologie a korpus
- PLIN032 Gramatika a korpus
- Korpusový workshop v Praze

Osnova

- Úvod – korpus a korpusová lingvistika, základní pojmy
- Vývoj korpusové lingvistiky
- Typy korpusů, české korpusy (ČNK)
- Budování korpusů, reprezentativnost
- Korpusové manažery
- Morfologické a syntaktické značkování
- Využívání korpusů
- Časopisy, konference, publikace
- *Praktická část*

Doporučená literatura

- Čermák, F. *Korpus a korpusová lingvistika*. Praha: Nakladatelství Karolinum, 2017.
- *Studie z korpusové lingvistiky*. Čermák, F., Klímová, J. a Petkevič, V. (eds.). Praha: Karolinum, 2000.
- Kennedy, G. *An Introduction to Corpus Linguistics.* London, New York: Routlege, 1998 (hardback 2016).
- McEnery, T. and Wilson, A. *Corpus Linguistics: An Introduction*. Edinburgh: Edinburgh University Press, 1996.
- McEnery, T. and Hardie, A. *Corpus Linguistics: Method, Theory and Practice*. Cambridge: Cambridge University Press, 2012.
- http://korpus.cz – Český národní korpus
- http://wiki.korpus.cz – výklad termínů
- NESČ https://www.czechency.org/

Instituce v ČR

- **Ústav Českého národního korpusu FF UK**
- Ústav teoretické a komputační lingvistiky FF UK
- Ústav formální a aplikované lingvistiky MFF UK
- Ústav pro jazyk český AV ČR
- Centrum zpracování přirozeného jazyka FI MU
- Ústav českého jazyka FF MU

Korpusová lingvistika

- **vymezení v systému věd**
- průnik **humanitních** (lingvistika) a **přírodních** (matematika, informatika) věd
  - studium **přirozeného** jazyka s využitím metod přírodních věd
- dostatečné množství autentických jazykových dat
- empirie, observace (x introspekce)
- objektivita a evidence
- opakovaný experiment
- **počítače a software**

Korpusová lingvistika

- **užší vymezení – vztah k NLP**
- lingvistika, matematika a informatika
- počítačová lingvistika
  - počítačové zpracování přirozeného jazyka, Natural Language Processing – NLP
- korpusová lingvistika
- **vymezení v rámci lingvistiky**
- samostatný obor
  - přístup corpus-driven, výzkum korpusem řízený
  - reformulování introspekcí stanovené hypotézy
- metodologie pro všechny části lingvistiky
  - přístup corpus-based, výzkum korpusem ověřovaný
  - exemplifikace hypotézy, hledání dokladů)

- poskytuje zdroj jazykových dat

Co je to korpus

Jazykový korpus (z lat. *corpus* „tělo, těleso“) je **rozsáhlý** soubor **autentických textů** (psaných nebo mluvených) převedený do **elektronické podoby** v jednotném formátu tak, aby v něm bylo možné jednoduše **vyhledávat** jazykové jevy, zejména slova a slovní spojení. Korpus zobrazuje jazykové jevy v jejich **přirozeném kontextu**, a umožňuje tak vytvářet na reálných datech podložený jazykový výzkum v rozsahu, který byl dříve nemyslitelný.

http://wiki.korpus.cz/doku.php/pojmy:korpus

Co je to korpus

Rozsáhlý soubor elektronicky uložených jazykových dat, obvykle označkovaný, organizovaný se zřetelem k využití pro určitý cíl, vůči němuž je také považován za reprezentativní.

Čermák, F. Jazykový korpus: Prostředek a zdroj poznání. In *Studie z korpusové lingvistiky.* Praha: Karolinum, 2000, s. 15–38.

Elektronický text v korpusu

- lineární řetězec znaků
  - psaný a mluvený
- jednotný kód (*Unicode – UTF-8*) a formát (*txt*)
- autentičnost – data se neupravují, korpus je **deskriptivní**
  - „Korpusová data jsou posvátná.“ (F. Čermák)
- etický kodex
- autorská práva

Co je to korpus – shrnutí

- elektronický soubor textů (rozsáhlý)
- autentické texty, slova v přirozeném kontextu – **konkordance**
- sjednocené texty
  - strojově čitelný formát, machine readable format/MRF
  - jednotné kódování
- **označkovaná data** (přidané informace)
- reprezentativní vůči svému účelu

Jak korpus vypadá uvnitř

- vertikál (vertikální text)
- token (tokenizace)
  - řetězec znaků ohraničený z obou stran mezerami
- type (word, slovní tvar n. lemma)
- token – type
  - **token-type ratio, type/token**
  - vysoké číslo = bohatost slovníku
  - nízké číslo = velké opakování slov
- pro uživatele – **korpusové manažery**
- konkordance, KWIC (key word in context)

2	<s>
3	Pro
4	představu
5	<g/>
6	,
7	jakým
8	přívětivým
9	místem
10	byl
11	Americký
12	park
13	v
14	minulosti
15	<g/>
16	,
17	uvádíme
18	několik
19	historických
20	fotografií
21	<g/>
22	.
23	</s>

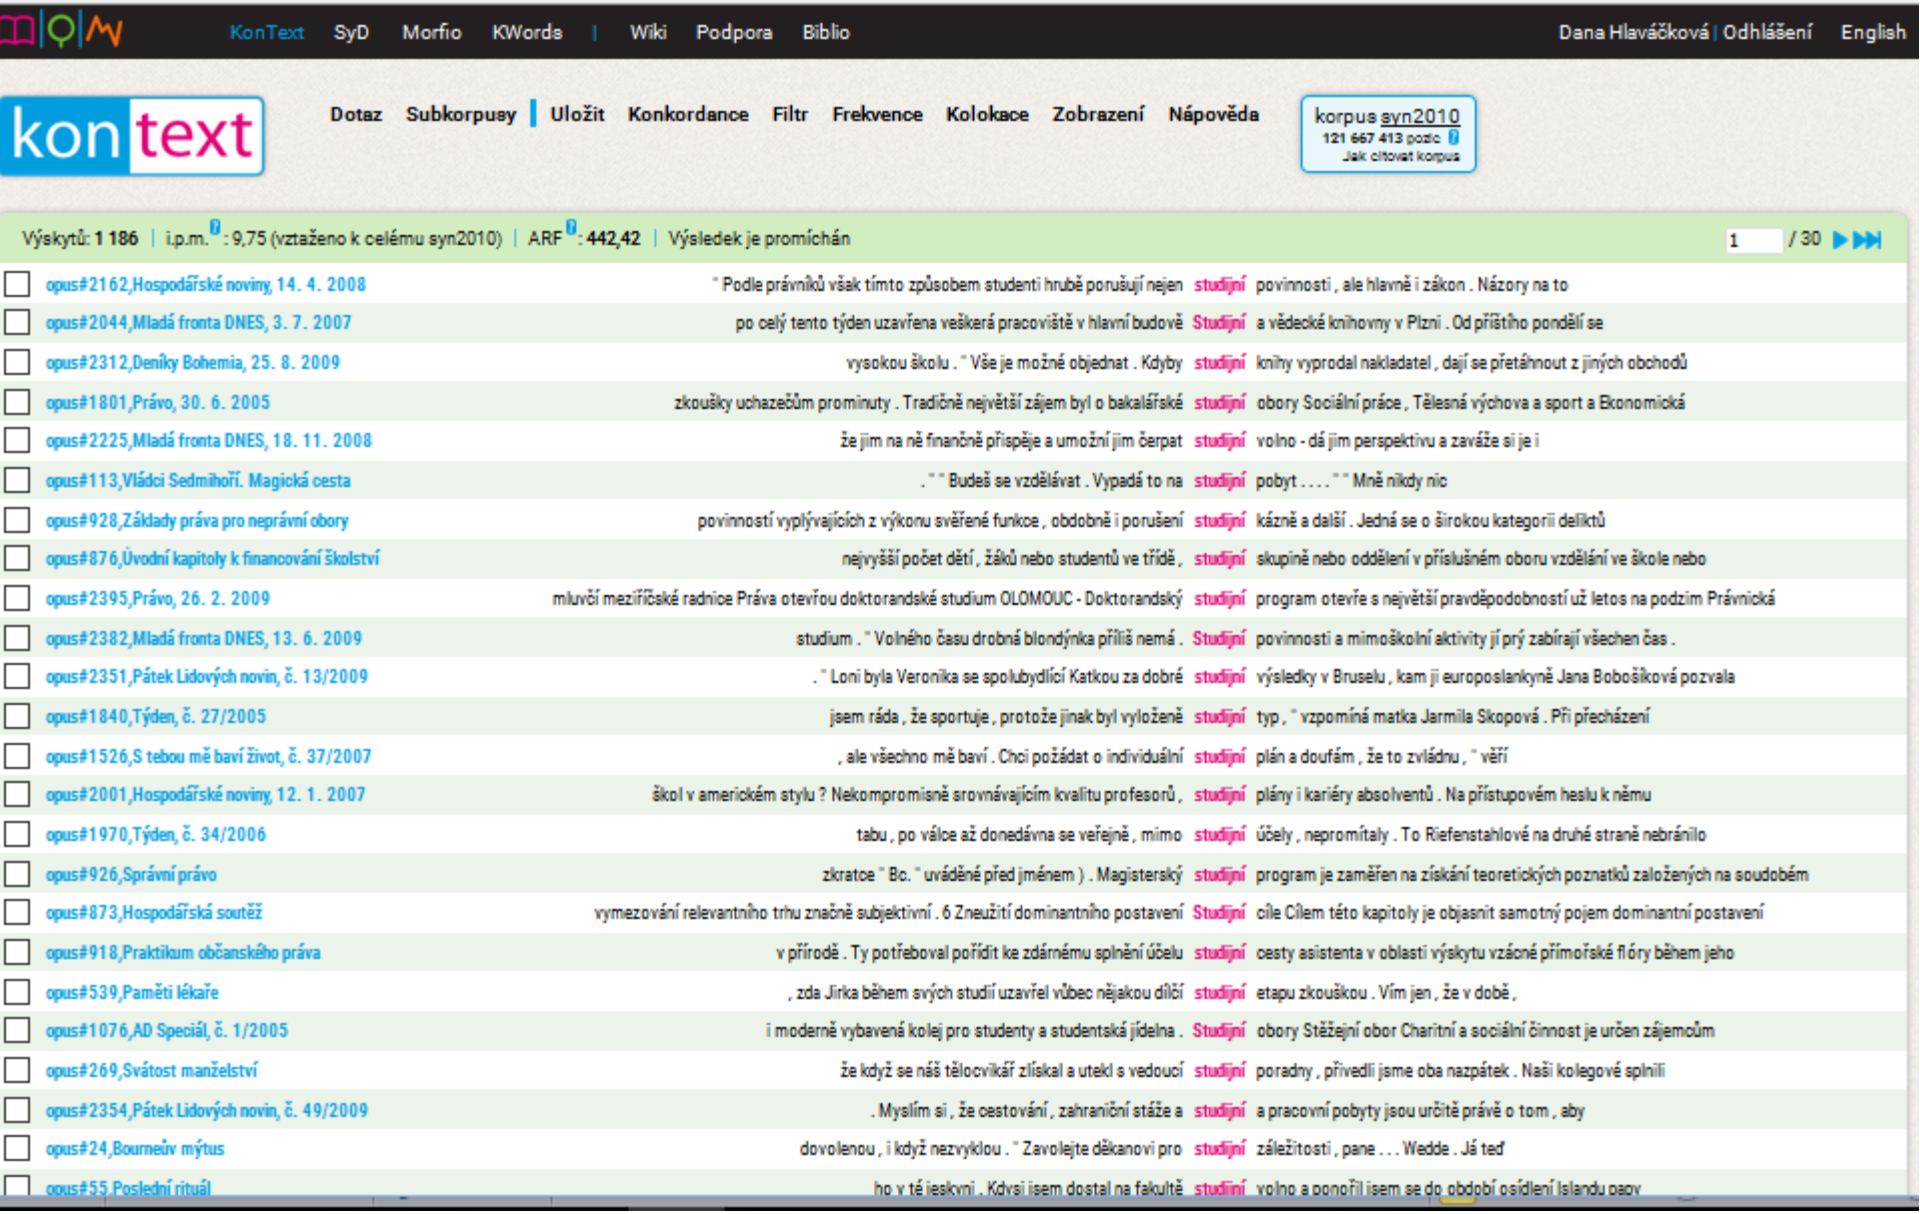
KonText SyD Morfio KWords | Wiki Podpora Biblio
Dana Hlaváčková | Odhlášení English
kontext
Dotaz Subkorpusy | Uložit Konkordance Filtr Frekvence Kolokace Zobrazení Nápověda
korpus syn2010
121 667 413 pozic
Jak citovat korpus
Výskytů: 1 186 | i.p.m.: 9,75 (vztaženo k celému syn2010) | ARF: 442,42 | Výsledek je promíchán
1 / 30
opus#2162,Hospodářské noviny, 14. 4. 2008 " Podle právníků však tímto způsobem studenti hrubě porušují nejen studijní povinnosti , ale hlavně i zákon . Názory na to
opus#2044,Mladá fronta DNES, 3. 7. 2007 po celý tento týden uzavřena veškerá pracoviště v hlavní budově Studijní a vědecké knihovny v Plzni . Od příštího pondělí se
opus#2312,Deníky Bohemia, 25. 8. 2009 vysokou školu . " Vše je možné objednat . Kdyby studijní knihy vyprodal nakladatel , dají se přetáhnout z jiných obchodů
opus#1801,Právo, 30. 6. 2005 zkoušky uchazečům prominuty . Tradičně největší zájem byl o bakalářské studijní obory Sociální práce , Tělesná výchova a sport a Ekonomická
opus#2225,Mladá fronta DNES, 18. 11. 2008 že jim na ně finančně přispěje a umožní jim čerpat studijní volno - dá jim perspektivu a zaváže si je i
opus#113,Vládci Sedmihoří. Magická cesta ." " Budeš se vzdělávat . Vypadá to na studijní pobyt . . . . " " Mně nikdy nic
opus#928,Základy práva pro neprávní obory povinností vyplývajících z výkonu svěřené funkce , obdobně i porušení studijní kázně a další . Jedná se o širokou kategorii deliktů
opus#876,Úvodní kapitoly k financování školství nejvyšší počet dětí , žáků nebo studentů ve třídě , studijní skupině nebo oddělení v příslušném oboru vzdělání ve škole nebo
opus#2395,Právo, 26. 2. 2009 mluvčí mezifiřské radnice Práva otevřou doktorandské studium OLOMOUC - Doktorandský studijní program otevře s největší pravděpodobností už letos na podzim Právnická
opus#2382,Mladá fronta DNES, 13. 6. 2009 studium . " Volného času drobná blondýnka příliš nemá . Studijní povinnosti a mimoškolní aktivity jí prý zabírají všechen čas .
opus#2351,Pátek Lidových novin, č. 13/2009 ." Loni byla Veronika se spolubydlící Katkou za dobré studijní výsledky v Bruselu , kam ji europoslankyně Jana Bobošíková pozvala
opus#1840,Týden, č. 27/2005 jsem ráda , že sportuje , protože jinak byl vyloženě studijní typ , " vzpomíná matka Jarmila Skopová . Při přecházení
opus#1526,S tebou mě baví život, č. 37/2007 , ale všechno mě baví . Chci požádat o individuální studijní plán a doufám , že to zvládnu , " věří
opus#2001,Hospodářské noviny, 12. 1. 2007 škol v americkém stylu ? Nekompromisně srovnávajícím kvalitu profesorů , studijní plány i kariéry absolventů . Na přístupovém heslu k němu
opus#1970,Týden, č. 34/2006 tabu , po válce až donedávna se veřejně , mimo studijní účely , nepromítaly . To Riefenstahlové na druhé straně nebránilo
opus#926,Správní právo zkratce " Bc. " uváděné před jménem) . Magisterský studijní program je zaměřen na získání teoretických poznatků založených na soudobém
opus#873,Hospodářská soutěž vymezování relevantního trhu značně subjektivní . 6 Zneužití dominantního postavení Studijní cíle Cílem této kapitoly je objasnit samotný pojem dominantní postavení
opus#918,Praktikum občanského práva v přírodě . Ty potřeboval pořídit ke zdárnému splnění účelu studijní cesty asistenta v oblasti výskytu vzácné přímořské flóry během jeho
opus#539,Paměti lékaře , zda Jirka během svých studií uzavřel vůbec nějakou dílčí studijní etapu zkouškou . Vím jen , že v době ,
opus#1076,AD Speciál, č. 1/2005 i moderně vybavená kolej pro studenty a studentská jídelna . Studijní obory Stěžejní obor Charitní a sociální činnost je určen zájemcům
opus#269,Svátost manželství že když se náš tělocvikář zlíbal a utekl s vedoucí studijní poradny , přivedli jsme oba nazpátek . Naši kolegové splnili
opus#2354,Pátek Lidových novin, č. 49/2009 . Myslím si , že cestování , zahraniční stáže a studijní a pracovní pobyty jsou určitě právě o tom , aby
opus#24,Bourneův mýtus dovolenou , i když nezvyklou . " Zavolejte děkanovi pro studijní záležitosti , pane . . . Wedde . Já teď
opus#55,Poslední rituál ho v té jeskyni . Kdysi jsem dostal na fakultě studijní volno a ponořil jsem se do období osídlení Islandu pap

Obsah a rozsah korpusu

- **typ komunikace** – korpusy psané, mluvené, multimodální
- obsah – typy textů
  - beletrie, odborné texty, publicistické texty
  - texty z internetu
  - soukromá korespondence
  - přepisy mluvených nahrávek
  - texty zahraničních studentů češtiny (žákovské korpusy)
- vyváženost (poměr kategorií)

Obsah a rozsah korpusu

- rozsah – velikost korpusu
  - počet tokenů
  - počet slov (type, word)
- opravdu velké korpusy (web jako korpus, webové korpusy – několik miliard pozic)
  - frekvenční studie
- malé specializované korpusy (stovky tisíc pozic, jednotky milionů)

Obsah a rozsah korpusu

- celé texty
- vzorky (sampling) – vybraná část textu
- rozsah
  - vymezený rozsah, uzavřený (předem stanoven) - **referenční**
  - otevřený/monitorovací korpus (plynule se zvětšuje) – **nereferenční**
  - korpus, který se pravidelně obnovuje a zvětšuje – **verzovaný** (verze se číslují)

Značkování korpusu

- značkování – zvyšuje informační hodnotu korpusu (vždy nutná dostupná interpretace značek = tagset)
- vnitřní značkování (vnitrotextové)
  - strukturní atributy (opus, doc, s)
  - morfologické značky
  - poziční atributy (word, lemma, tag)

- vnější značkování, (vnětextové)
  - na úrovni textu, **metatextové** informace (autor, název díla, rok vydání atd.)

Hlavní rysy korpusu

- *aneb čím se korpus liší od webu nebo elektronického archivu*

1. **elektronické texty v jednotném formátu**
2. **značkování**
3. **zobrazení konkordancí v korpusových manažerech**
4. **vymezený obsah a rozsah**