



Korpusy pro překladatele (španělština)

Jarmila Fictumová
KAA FF MU

Korpusy

- **JEDNOJAZYČNÉ**: cizojazyčné, české; všeobecné, specializované (dle žánru či odborné, ad hoc)
- **DVOJJAZYČNÉ**: paralelní (= překladové); srovnatelné (pro vyhledávání odborné terminologie)
- **STUDENTSKÉ** (neboli žákovské – tj. *learner*): jednojazyčné; překladové (výuka překladu)

ZÁKLADNÍ TERMINOLOGIE UŽÍVANÁ V KORPUSOVÉ LINGVISTICE

- **ANOTACE** (značkování; tagování): přidělení explicitní lingvistické informace k textu (větné členy a sémantická anotace)
- **CÍLOVÝ JAZYK (CJ)**: jazyk, do kterého překládáme
- **CQL (CONTEXTUAL QUERY LANGUAGE)**: vyhledávací jazyk
- **DIACHRONNÍ KORPUS**: studuje vývoj jazyka za určité delší časové období
- **KONKORDANCE**: bezprostřední kontext dané lexikální jednotky

ZÁKLADNÍ TERMINOLOGIE UŽÍVANÁ V KORPUSOVÉ LINGVISTICE

- **KORPUS:** obsáhlá sbírka autentických textů v elektronické podobě (psaných textů nebo transkripce mluveného jazyka), shromážděných podle určitých kritérií)
- **KORPUSOVÝ MANAŽER:** software, který nachází konkordance pro hledané termíny, nachází všechny jejich výskyty v daném korpusu
- **KWIC (KEY WORD IN CONTEXT):** zobrazení slova v jeho kontextu; obvykle ve středu monitoru
- **LEMMA:** slovní tvar, který je dohodou vybrán jako reprezentant všech souvisejících forem
- **LEXÉM (ANGL. TYPE):** každé různé slovo v korpusu (např. *Žil u lesa u řeky* - 4 lexémy, ale 5 tvarů slova / tokenů)
- **OTEVŘENÝ KORPUS:** korpus, který je pravidelně doplňován

ZÁKLADNÍ TERMINOLOGIE UŽÍVANÁ V KORPUSOVÉ LINGVISTICE

- **PARALELNÍ KORPUS:** různojazyčné texty – překlady, zarovnané většinou po větách, podobně jako překladové paměti
- **SROVNATELNÝ KORPUS:** různojazyčné texty, které nejsou překladem, ale mají některé společné rysy (typ textu, téma...)
- **SYNCHRONNÍ KORPUS:** nestuduje vývojové změny jazyka
- **TOKENY:** všechna slova obsažená v korpusu bez ohledu na tvar
- **VÝCHOZÍ / ZDROJOVÝ JAZYK (VJ):** jazyk ze kterého překládáme
- **ZAROVNÁVÁNÍ (ALIGNMENT):** nalezení a přiřazení odpovídajících úseků jinojazyčných textů v paralelních korpusech
- Více na [Přehled základních pojmů korpusové lingvistiky](#)



Korpusové nástroje

Informace z článku Jazykové korpusy pomáhají s psaním textů (MUNI.CZ 14.1.2014)

Zuzany Nevěřilové, která působí v Centru zpracování přirozeného jazyka Fakulty informatiky MU a vyučuje v Centru počítačové lingvistiky Filozofické fakulty MU.



Software s názvem [Sketch Engine](#) vyvíjí společnost Lexical Computing ve spolupráci s [Centrem zpracování přirozeného jazyka](#) Masarykovy univerzity už přes deset let. Všichni studenti a zaměstnanci mají k tomuto programu, založeném na jazykových korpusech, [volný přístup](#). ...

... Sketch Engine vypočítá slovní profil (takzvaný word sketch), který ukáže, s jakými slovy-partnery se kandidát vyskytuje společně, jak často a v jakých kontextech. ...

... Ze slovních profilů pak dokáže Sketch Engine vypočítat na větších celcích (frázích) dobré partnery. Výsledkem takového výpočtu je tedy Tezaurus, pomocí kterého najdeme významově blízka slova. ...

... Software ale obsahuje i řadu dalších pokročilých funkcí pro práci s vlastními korpusy (automatickou extrakci klíčových slov, subkorpusy podle délky dokumentu či atributů autora) nebo pro práci s vícejazyčnými (paralelními) korpusy. Sketch Engine nabízí v současnosti více než 400 korpusů pro 70 jazyků. Všechny funkce jsou [popsány v dokumentaci](#).

[Dokumentace ve španělštině](#)



WEBOVÉ KORPUSY

(VÍCE INFORMACÍ [v článku o přednášce](#) ING VLADIMÍRA BENKA)

▪ ŠPANĚLSKÉ KORPUSY

- [esTenTen11 \(American, Freeling\)](#)
- [esTenTen11 \(European, TreeTagger\)](#)
- [EUROPARL5, Spanish-English](#)
- [OPUS2 Spanish](#)
- [Spanish web corpus](#)

▪ ČESKÉ KORPUSY

- [czTenTen12 \[v. 7\]](#)
- [OPUS2 Czech](#)
- [CzechParl 2012](#)
- [Bruna Bohemica Minor \(czes 14.04\) 121 M](#)

ČNK




Kliknutím na logo se zobrazí formulář registrace.

kon text

- MANUÁL PRÁCE S KORPUSOVÝM ROZHRANÍM

Lze očekávat, že bude zpřístupněn i webový korpus Araneum Hispanicum. Zatím jen Araneum Slovacum.

CIZOJAZYČNÉ KORPUSY



Mark Davies: Professor, Corpus Linguistics, Brigham Young University

[Corpus del Español](#)

[Google Books: Spanish](#)

Další možnosti



- [University of Leeds: tutoriál v angličtině](#)



PILOTNÍ PROVOZ



hypoal

NÁSTROJ NA VYTVÁŘENÍ PARALELNÍCH KORPUSŮ A STUDENTSKÝCH
KORPUSŮ JEDNO- I DVOJAZYČNÝCH S OZNAČOVÁNÍM CHYB



Dotazy?



Děkuji vám za pozornost!