

# Korpusová lingvistika – 3

Mgr. Dana Hlaváčková, Ph.D.

CJBB105

# Typy jazykových korpusů

- znalost různých typů korpusů
- schopnost vybrat správný korpus pro svoji práci
- v průběhu času přibývají nové typy
- různá kritéria dělení
  - z hlediska obsahu, rozsahu, způsobu budování
- stejné typy korpusů v celosvětovém měřítku
- národní korpusy a subkorpusy
- každý korpus má více přívlastků

# Typy jazykových korpusů

- typ zachycené komunikace
  - **psané** korpusy (Written Corpora)
  - hraniční typ – soukromá korespondence, KSK
  - v ČNK – korpusy řady SYN, PUB
  - **mluvené** korpusy (Spoken Corpora)
  - včetně čtení předem připraveného psaného projevu
  - v ČNK – PMK, BMK, řada ORAL, ORTOFON
- časový záběr
  - **synchronní** – cca 2. pol. 20 st. – současnost
  - korpusy řady SYN, PUB
  - **diachronní** – 13. st. – 1945 (beletrie)/1989 (publicistika, odborné texty)
  - DIAKORP

# Typy jazykových korpusů

- zachycený jazyk
  - **jednojazyčné** – např. SYN2015
  - **paralelní** – InterCorp, ORWELL (stejné texty v překladech do různých jazyků)
  - psané **srovnatelné** korpusy (Comparable Corpora) – Aranea (14 jazyků, V. Benko)
    - shodná metodika tvorby, srovnatelná velikost, čas pořízení textů, způsob budování
- účel
  - **všeobecné** – řada SYN, ORAL (psané, mluvené, synchronní, bez speciálního zaměření)
  - **specializované** – např. KSK, BMK
    - **žákovské** korpusy (Learner Corpora) – psané texty češtiny produkované nerodilými mluvčími

# Typy jazykových korpusů

- způsob budování
  - **tradiční** – poskytovatelé textů (autorský zákon), elektronické texty, OCR
  - SYN2013PUB
    - **mluvené** – nahrávka, přepis
    - **webové** – texty stahované z internetu
      - ukWaC, CzTenTen12 (CZPJ FI MU)
- možnost rozšíření
  - uzavřené – **referenční**, neměnný v čase, zpětně dostupný
    - jiný význam – při porovnávání frekvence jevů – standard, vzor obecného užívání jazyka
  - otevřené – **nereferenční**

# Typy jazykových korpusů

- značkování
  - **neoznačkované** (morfologicky) – BMK, KSK, DIAKORP
  - značkované (morfologicky)
    - **lemmatizace** (přiřazení základních tvarů slov)
    - **tagging** (lemmata + morfologické značky), PoS tagging
  - značkované (foneticky, syntakticky)
    - **fonetická transkripce** – OMK (Katedra bohemistiky UP Olomouc, dr. Petr Pořízka), ORTOFON
    - **syntax** – PDT (ÚFAL MFF UK Praha)
- verzované korpusy – SYN v. 5, InterCorpu v. 9

# British National Corpus (BNC)

- vedoucí role – Geoffrey Leech
- jednojazyčný, synchronní, vyvážený, reprezentativní, široký průřez britskou angličtinou z konce 20. st., 1991–1994
- BNC Consortium (Oxford University Press), British Library, British Academy
- 100 mil. slov, 90 % psaný jazyk (vzorky po 45 tis. slovech), 10 % mluvený
- publicistika, beletrie, odborná literatura, formální i neformální promluvy
- PoS Tagging

# Ústav Českého národního korpusu

- **ÚČNK FF UK**, Panská ul., Praha, [www.korpus.cz](http://www.korpus.cz)
- založen 1994, ředitel prof. F. Čermák, od r. 2013 doc. V. Cvrček, od 2015 dr. M. Křen
- spolupráce s Ústavem teoretické a komputační lingvistiky FF UK a Ústavem formální a aplikované lingvistiky MFF UK
- budování ČNK
- publikační činnost
- výuka pro magisterský stupeň
- výuka pro doktorský stupeň – obor Matematická lingvistika

# Český národní korpus

- korpusy řady **SYN** (všeobecný korpus, psaný synchronní jazyk, referenční korpusy, celkem 2,2 mld. slov, lemmatizace, morf. značkování)
  - **SYN2000** – 1990–1999, 100 mil. slov
    - beletrie 15 %, odborná lit. 25 %, publicistika 60 %
  - **SYN2005** – 2000–2004, 100 mil. slov
    - beletrie 40 %, odborná lit. 27 %, publicistika 33 %
  - **SYN2010** – 2005–2010, 100 mil. slov
    - beletrie 40 %, odborná lit. 27 %, publicistika 33 %
  - **SYN2015** – 2011–2015, 100 mil. slov
    - beletrie 33 %, odborná lit. 33 %, publicistika 33 %
- **SYN2006PUB** – 1989–2004, 300 mil. slov
- **SYN2009PUB** – 1995–2007, 700 mil. slov
- **SYN2013PUB** – 2005–2009, 935 mil. slov

# Český národní korpus

- specializované korpusy, např.
- **KSK-DOPISY** – ručně psané dopisy z let 1990–2004, 800 tis. slov
- **ORWELL** – román G. Orwella 1984, ručně značkovaný, 80 tis. slov, 2003 (MULTEXT-East, 12 jazyků, paralelní korpus)
- **CzeSL-Plain** – žákovský korpus nerodilých mluvčích, 2 mil. slov, 2012 (eseje cizinců, odborné závěrečné práce, slohové práce romských žáků)
- **LINK** (Lingvistův Narozeninový Korpus k výročí prof. F. Čermáka), odborné lingvistické texty z let 1985–2010, 1,8 mil. slov

# Český národní korpus

- diachronní korpus **DIAKORP** v. 6, 2005
- 3,4 mil. slov, nereferenční
- texty od konce 13. st. po hranice synchronní složky (48 % z 19. st.)
- různorodost textů – pravopisné systémy, tisky, rukopisy
- transkripce (rekonstrukce)
- vnětextové i vnitrotextové značkování, např. nezřetelné/nečitelné úseky, cizojazyčné citáty, poznámky pod čarou (bez morfologie)
- využití tzv. hyperlemmat (kůň – kuoň, kóň)

# Český národní korpus

- paralelní korpus **InterCorp**, 1. verze 2008, nereferenční
- 1,46 mld. slov (verze 9, 2016), 30 jazyků
- párování (alignment), čeština = pivot
- jádro (core) korpusu – ručně zarovnané hl. beletristické texty
- kolekce (collection) – texty zarovnané automaticky
  - publicistika a zpravodajství z webu
  - právní texty Evropské unie
  - zápisy z jednání Evropského parlamentu 2007–2011 (Europarl)
  - filmové titulky z databáze Open Subtitles

# Český národní korpus

- srovnatelné webové korpusy **Aranea** (dr. Vladimír Benko, Bratislava)
- 2014, nereferenční, 14 jazyků, stejná velikost, stejná metodika a technologie tvorby
- open-source (volně dostupné) nástroje, PoS tagging
- základní velikost
  - 1,2 mld. slov = maius,
  - 10% vzorek, 120 mil. = minus, určeny pro vyučování
  - 10 mil. = minimum, pro testování nástrojů
  - maximum – „kol'ko sa podarí“, 5,5 mld. jen pro češtinu

# Korpusy v CZPJ FI MU

- **CzTenTen12** – webový korpus z r. 2012
  - značkovaný (morphologie), 4,2 mld. slov
- **Czes** – novinové články z let 1995–1998 a 2002, 350 mil. slov
- **OPUS2 Czech** – česká část paralelního webového korpusu
  - Jörg Tiedemann, Uppsala University
- **CNPK** – česko-německý paralelní korpus, Katedra německého jazyka a literatury PedF MU, 2005, celkem přes 7 mil. slov, snaha o vyváženosť
- **chyby2** – texty studentů FI MU s vyznačenými chybami, 50 tis. slov
- **DESAM** – 1 mil. slov, ruční desambiguace, referenční korpus

# Přístup ke korpusům

- Český národní korpus <http://wiki.korpus.cz/doku.php/cnk:uvod>
- Sketch Engine <http://ske.fi.muni.cz>
- Aranea <http://unesco.uniba.sk/aranea>