CJBB105 – 4
Korpusové manažery

Mgr. Dana Hlaváčková, Ph.D.

CJBB105

PRZA009

Korpusové manažery

- umožňují **zpracování textů** do korpusové podoby (tokenizace, vertikál, značkování)
- **prohlížení** korpusových dat a **práci s nimi** (řada fcí)
- **budování korpusů**
  - pouze některé manažery, v ČR Sketch Engine
- poskytují navazující **aplikace** spojené s korpusovým zpracováním dat
- vývoj:
  - desktopová aplikace – starší typ, nutná instalace do počítače
  - webová stránka – jednoduchý typ, v některých zemích, omezené fce
  - **webové rozhraní** – nejčastější současný typ, pro všechny prohlížeče a operační systémy, uživatelská přívětivost
- často omezený přístup (pouze ukázky), nutná registrace, příp. i stažení a instalace (v některých zemích)

Historie českého manažeru

- 1995 – cesta do Velké Británie po **centrech korpusové lingvistiky**
  - Karel Pala (FI MU), František Čermák (ÚČNK), Vladimír Petkevič (ÚTKL), Věra Schmiedtová (ÚČNK)
- cílem bylo načerpat informace, zkušenosti a získat korpusový manažer
- Oxford University Press, University of Oxford – **Patrick Hanks**
- School od English, Birmingham City University – **John Sinclaire**
- Lancaster University – **Geoffrey Leech**
- byly navázány kontakty, ale nikdo manažer neposkytl
- příprava vlastního českého korpusového manažeru – Pavel Rychlý (FI MU)
  - převzal CQP (Corpus Query Processor, Universität Stuttgart, Institut für Maschinelle Sprachverarbeitung, prof. Ulrich Heid, autoři CQP Schulze a Christ)
- na jeho základě vytvořil **Manatee Bonito** (server-klient), dizertační práce (r. 2000)
- na něm jsou postaveny současné manažery **Sketch Engine** a **KonText**

Původní manažer **Bonito**, desktopová aplikace, 90. léta 20. st. až cca 2014 (od 2003 začíná vývoj Sketch Engine) používal se v celé ČR i pro ČNK, manažer byl velmi oblíbený, lingvisté ho neradi opouštěli a přecházeli na webové rozhraní

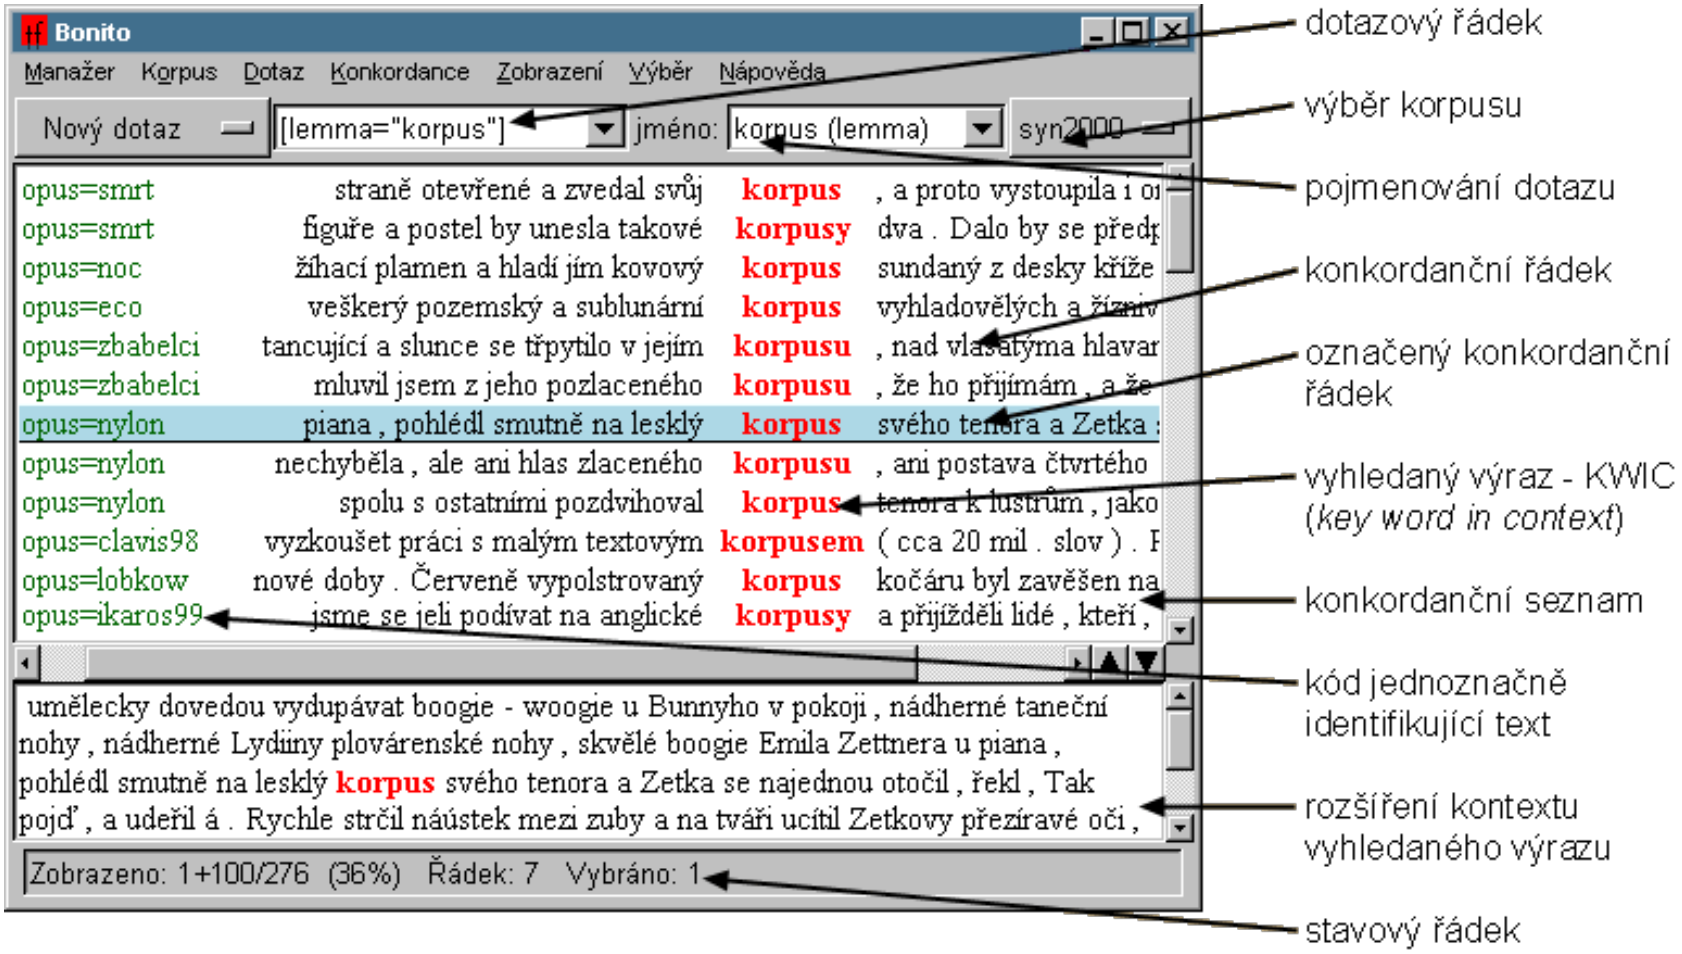

Korpusové manažery – vývoj

- jádro – **Manatee** (server), korpusové zpracování textů, **Bonito** – klient (Pavel Rychlý, FI MU)
  - Manatee + **Bonito**
  - **Bonito2** – první webové rozhraní, používalo se krátce, přešel pod něj i ČNK
  - **Sketch Engine** (placená verze, pro MU zdarma), **NoSketch Engine** (zdarma bez některých fcí) – krátkou dobu užíval i ČNK
- současná webová rozhraní
  - Sketch Engine – MU (CZPJ FI MU + Lexical Computing, Ltd.), Brno
  - KonText – ÚČNK, Praha, využívá Manatee a vychází z NoSketch Engine (Tomáš Machálek)

Prohlížení korpusu a fce manažeru KonText

- Sketch Engine
- https://www.sketchengine.eu/

- doporučuji zaregistrovat se k ČNK, abyste mohli využívat všechny fce rozhraní https://korpus.cz/signup
- KonText https://kontext.korpus.cz/
- manuál ke KonTextu najdete zde https://wiki.korpus.cz/doku.php/manualy:kontext:index

Možnosti hledání – Dotaz (co a jak je možné v korpusu hledat)

- *používám zkratky pro KonText (KT) a Sketch Engine (SKE) pro upozornění na rozdíly mezi manažery, jinak fce platí pro oba*
- konkrétní tvar slova (*slovo, slovní tvar, word*)
- lemma – nalezeny všechny tvary zadaného slova vyskytující se v korpusu
- fráze (SKE) – spojení dvou a více slov s výskytem těsně vedle sebe
- znak (SKE)
- CQL (Corpus Query Language) – dotazovací jazyk
  - konstrukce značky (KT), nápověda pro uživatele
  - CQL builder (SKE)
  - [word=„ježkem“] – formální podoba dotazu v CQL
- specifikace dle **kontextu** – možnost vyhledávat podle kontextu zadaného tvaru
- specifikace dle **metainformací** – možnost vyhledávat podle metadat o textech
- **regulární výrazy** – znaky umožňující efektivnější hledání v korpusech, viz https://wiki.korpus.cz/doku.php/pojmy:regularni_vyrazy

Možnosti zobrazení

- uživatel vidí **vybraný korpus**, počet nalezených **výskytů**
  - **i.p.m.** – *instances per million* (počet výskytů na milion pozic, důležitý údaj při srovnávání výsledků z různě velkých korpusů)
  - **ARF** – *average reduced frequency* (průměrná redukovaná frekvence vzhledem k rozložení tvaru v korpusu, odstraňuje problém, kdy je nějaký tvar frekventovaný např. jen v jednom typu dokumentů) **KT**
  - **procento v korpusu SKE**
- Funkce **Zobrazení**
- zobrazení ve formě konkordance (**KWIC**) nebo **věty** (možnost přepínání)
- poziční atributy – word, lemma, tag, lc (lowercase), část tagu
- strukturní značky – hranice vět, dokumentů ad.
- reference – metainformace o textech
- možnost nastavit šířku kontextu, počet konkordancí na stránku
- možnost zobrazit popis dotazu (konkordance)

Třídění výsledků

- možnost vygenerovat **náhodný vzorek**
- možnost **promíchání výsledků**
- třídění kontextu a KWIC (podle abecedy)
  - podle atributů
  - víceúrovňové a retrográdní
- filtrování konkordancí
  - pozitivní a negativní filtry (uživatele definuje, co chce ve výsledcích nechat, nebo co chce odstranit)
  - pouze 1. výskyt v dokumentu (odfiltruje vše kromě 1. výskytu v dokumentu)

Frekvenční distribuce

- **frekvenční údaje** – číselné i grafické znázornění
  - KWIC (lemmata, slovní tvary)
  - tagy
  - typy dokumentů
  - víceúrovňové
- vizualizace frekvenčního rozložení přes celý korpus (SKE)

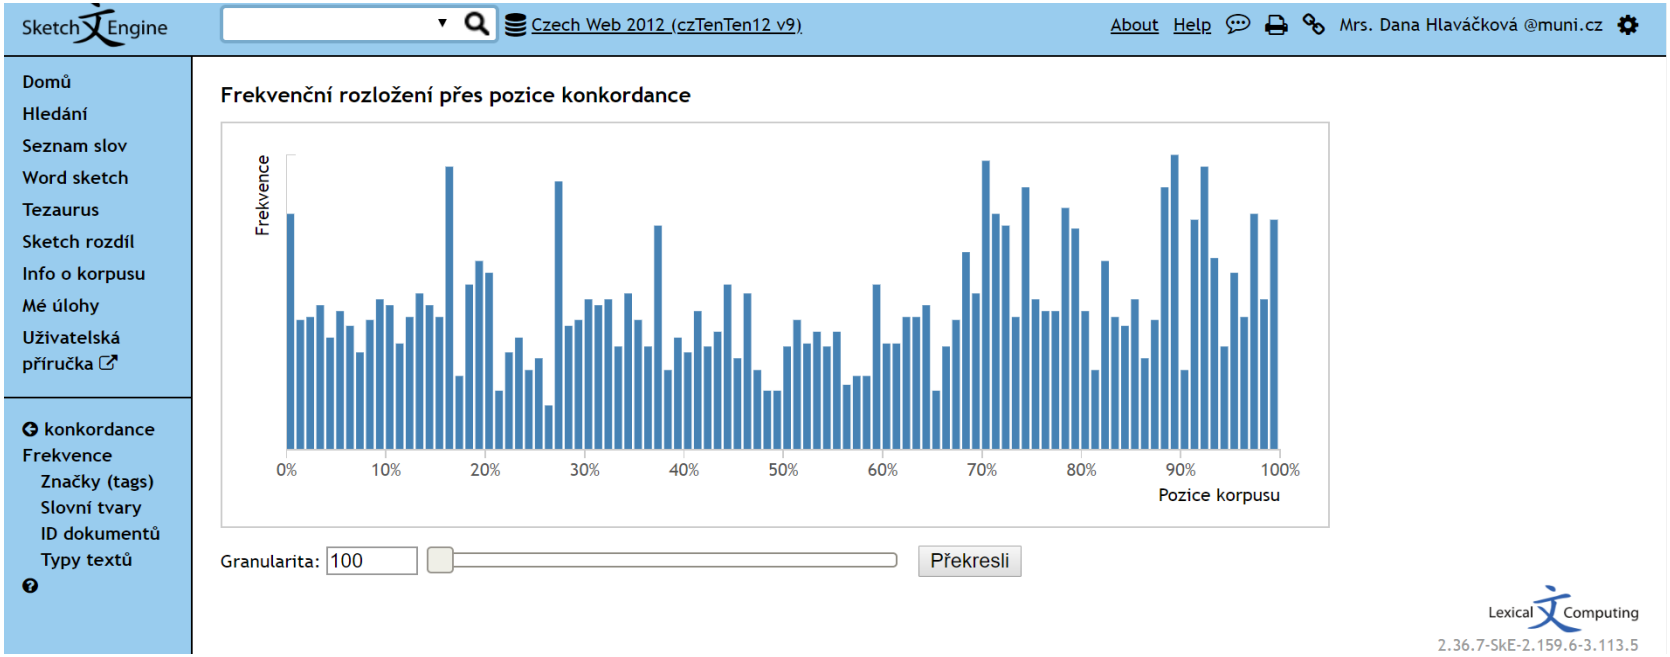

Frekvenční seznam tvarů lemmatu „kočka“ v korpusu SYN2015

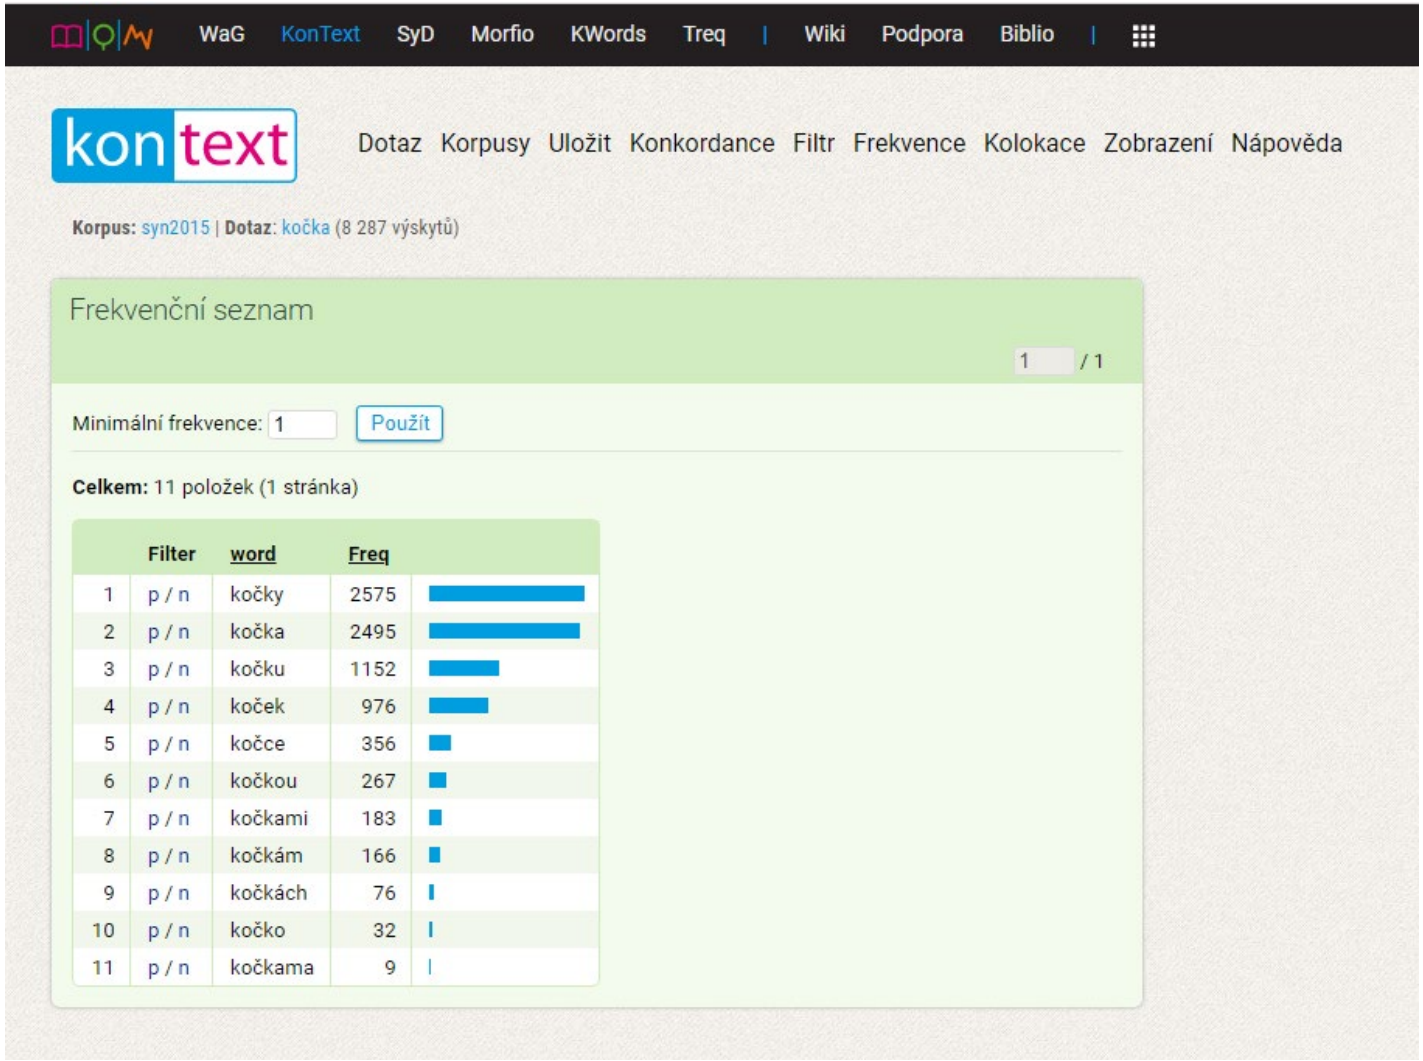

	Filter	word	Freq
1	p / n	kočky	2575
2	p / n	kočka	2495
3	p / n	kočku	1152
4	p / n	koček	976
5	p / n	kočce	356
6	p / n	kočkou	267
7	p / n	kočkami	183
8	p / n	kočkám	166
9	p / n	kočkách	76
10	p / n	kočko	32
11	p / n	kočkama	9

Kolokace

- výpočet kandidátů na kolokace (ustálená slovní spojení)
  - frekvence spojení (dvou a více jednotek) – vysoká
  - frekvence spojení s ostatními jednotkami – nízká
    - vztaženo k velikosti korpusu
  - můžeme sledovat kolokační paradigma, např. monokolokabilita (*stroužek česneku, tratoliště krve – stroužek* a *tratoliště* se nepojí s jinými slovy)
- **asociační míry** (číselné hodnoty, které dokládají kolokabilitu slov)
- MI-score
  - pravděpodobnost současného výskytu dvou slov (mutual information)
- T-score
  - zapojeno rozložení spojení slov přes celý korpus, nenáhodný jev
- Dice, Log-Dice
  - nepočítají s velikostí korpusu

Další funkce

- vytvoření subkorpusu
  - podle metainformací o textech (KT)
  - z aktuálních konkordancí (SKE)
- seznam slov
  - podle frekvence
  - uživatel definuje kritéria
- uložení výsledků v různých formátech

KonText – externí funkce

- SyD https://wiki.korpus.cz/doku.php/manualy:syd?redirect=1
  - korpusový průzkum variant slov
  - synchronní i diachronní korpusy
  - psaný i mluvený jazyk
- Kwords https://wiki.korpus.cz/doku.php/manualy:kwords?redirect=1
  - generování klíčových slov
  - porovnání výskytů s referenčním korpusem
- Morfio https://wiki.korpus.cz/doku.php/manualy:morfio?redirect=1
  - vyhledání seznamů slov (až n-tic) na základě slovotvorných charakteristik
- Treq https://treq.korpus.cz/
  - databáze překladových ekvivalentů
- Slovo v kostce https://www.korpus.cz/slovo-v-kostce/ (vyzkoušejte)

Sketch Engine

- https://www.sketchengine.eu/
- LOG IN – Institutional Login – Masarykova univerzita – UČO + primární heslo
- OVLÁDACÍ PANEL
  - **Konkordance** (Concordance) – hledání v korpusu
  - v Profil – Nastavení – možnost přepnout do češtiny
  - funkce jsou stejné jako v KonTextu (s drobnými rozdíly)
- manuál, vysvětlení termínů (Glossary) v angličtině https://www.sketchengine.eu/guide/

Sketch Engine – externí funkce

- Tezaurus – podobná slova, míra podobnosti na základě kontextů, vizualizace
  - hra Uhádni to slovo (podle kterého synonyma je vytvořen wordcloud, *https://nlp.fi.muni.cz/projekty/uhadni_to_slovo/*)
- Word Sketch – slovní profily, na základě morfol. značkování
  - tabulky zachycují okolí zadaného lemmatu podle určitých kategorií
- Sketch Diff – porovnání slovních profilů dvou lemmat
- tvorba korpusů a subkorpusů a další aplikace
- SkELL – generování příkladových vět z korpusu
  - https://skell.sketchengine.eu/