

PA153 Počítačové zpracování přirozeného jazyka

08 - Lexikografické nástroje a počítačová lexikografie

Karel Pala, Adam Rambousek

Centrum ZPJ, FI MU, Brno

16. listopadu 2015

1 Lexikografie

- Úvod
- Historie
- Slovníky a počítače

2 Počítačová lexikografie

- Reprezentace dat
- TEI
- LMF
- Dictionary Writing Systems

3 Tvorba slovníku

- Lexikální databáze
- Slovník

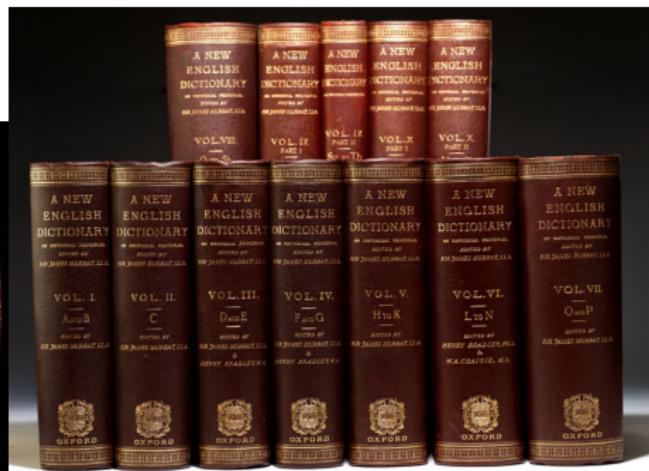
Lexikografie

- PLIN035 Počítačová lexikografie
- podoblast **lexikologie**
- lexicography, **lexikografie**
 - ▶ *the activity or occupation of compiling dictionaries* (Oxford d.)
 - ▶ *the editing or making of a dictionary* (Merriam-Webster d.)
 - ▶ *the job of writing a dictionary* (Macmillan d.)
- praktická lexikografie
- teoretická lexikografie - analýza a popis slovní zásoby, teorie o prvcích slovníku, skupinách uživatelů, hodnocení
- *Slovník národního jazyka* náleží mezi první potřebnosti vzdělaného člověka.



Historie

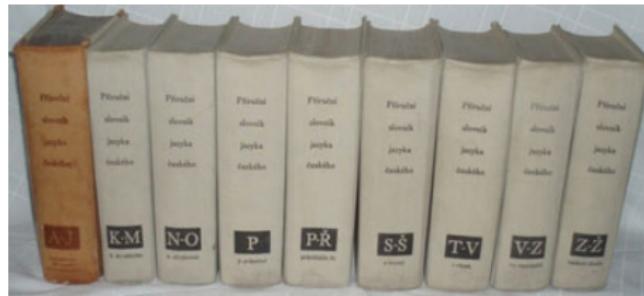
- hliněné tabulky z Ebla (Sýrie), cca 2500-2250 př.n.l.
 - ▶ sumerština - eblaština
- *The Oxford English Dictionary (A New English Dictionary)*
 - ▶ 1857, Philological Society, R. C. Trench, kritika slovníků
 - ▶ 1879, James A. H. Murray jmenován hlavním editorem
 - ▶ 1882-1928, vychází 12 svazků, 15 487 stran, 240 000 hesel



Historie

- *Kancelář Slovníku jazyka českého, 1911*

- ▶ sběr slovníkového materiálu, dobrovolníci
- ▶ výpisky z prózy, básní, odborné literatury, publicistických článků
- ▶ *Příruční slovník jazyka českého, 1935-1957*
- ▶ 10 824 stran, 250 000
- ▶ hesel cenzura "nežádoucích spisovatelů"



Slovníky a počítače

- 60. léta - používají se počítače, lexikografové píší na papír, specialisté přepisují do databáze, Brown Corpus
- 1978, *Longman Dictionary of Contemporary English*
 - ▶ první s omezeným slovníkem definicí, kontrolováno strojově
 - ▶ kódování pro NLP výzkum
- 1980, *COBUILD*, University of Birmingham + Collins
 - ▶ korpus současných textů (Bank of English)
 - ▶ 1987, *Collins COBUILD English Language Dictionary*
 - ▶ první slovník založený na korpusových datech
 - ▶ nový styl definice - celé věty
 - ▶ *If a person, animal, or other living thing is killed, something or someone causes them to die.*
- 90. léta - vývoj specializovaných systémů pro tvorbu slovníků
- 1987, Text Encoding Initiative

XML

- PB138 Moderní značkovací jazyky
- eXtensible Markup Language - značkovací (meta)jazyk
- pravidla, jak má vypadat správně vytvořený dokument - snadné strojové zpracování a výměna informací
- konkrétní názvy značek určuje uživatel (standardy, vlastní)
- elementy <značka>obsah</značka>
- bez obsahu lze <značka></značka> zkrátit na <značka/>
- atributy <značka atribut="hodnota"/>



Popis struktury a kontrola obsahu

- **DTD (Document Type Definition)**
 - ▶ seznam elementů a atributů a vztahy mezi nimi
 - ▶ nekontroluje obsah
 - ▶ `<!ELEMENT vyznam (definice, priklad+)>`
 - ▶ `<!ATTLIST vyznam cislo CDATA #REQUIRED>`
- **XML Schema (XSD, XML Schema Definition)**
 - ▶ popis obsahu a struktury XML dokumentu, schéma samotné je XML dokument
 - ▶ elementy, atributy, struktura
 - ▶ možnost určit vlastní typy obsahu (např. opakující se adresa)
 - ▶ kontrola obsahu (např. číselný rozsah, regulární výrazy, povolené hodnoty)

Zobrazení

- **XSLT** – eXtensible Stylesheet Language (Transformations)
- převod XML na jiné formáty
 - ▶ jiné XML značkování, text, HTML, LaTeX, PDF
- šablony pro části XML dokumentu, postupné procházení dokumentu
- funkcionální programovací jazyk

ssjc Slovník spisovného jazyka českého

lov

-u m. (6 j. -u)

1. **stíhání a zmocňování se zvěře (nejč. odstíolem); chytání ryb:** I. jelenu, divokých kachen, velryb; I. lososů; I. perel; doba lovů; uspořádat I. na medvědy; vyjet na I.; právo lovů; I. odstíolem, chytáním, lapáním; I. lesní, polní, vodní; hromadný I. [hon](#); liška vyšla na I.; lovů zdar! ([lovecký posdívav](#))
2. [expr](#) **chytání, shánění čehokoliv, vůbec získávání, při kterém se uplatní obratnost a náhoda:** I. vzácného hmyzu; sběratelé se vydali na I. lidových písniček; policie podnikla I. na zloděje; [expr](#) to je I! [štastný nález](#), výhodná koupě [ap.](#)
3. **výsledek lovů; úlovek, kořist:** vrátit se s bohatým lovem z ulovenou zvěří [ap.](#), [přen. expr](#) s věcmi získanými obratností I. [štastnou náhodou](#)

ssc Slovník spisovné češtiny

lov

-u m

1. **lovení zvěře a ryb** lov koroptví, lov na zajice, liška vyšla na lov,
2. [úlovek \(syno\)](#) [kořist \(syno\)](#) mit bohatý lov,

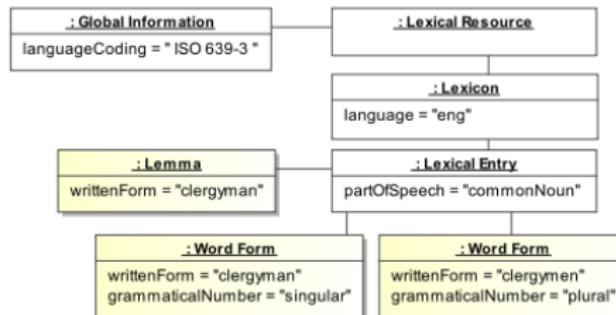
Ukládání

- XML databáze
- ukládají se přímo XML dokumenty
- vyhledávání - XPath, XQuery
- např. eXist, BaseX, Sedna

- *Text Encoding Initiative*, <http://www.tei-c.org/>
- *TEI Guidelines* (aktuálně verze 5 z roku 2007)
- XML formát pro sémantický popis textových dokumentů
- velký rozsah značek
- *TEI Lite* – osekaná verze, "90 % potřeb 90 % uživatelů"
- romány, poezie, divadelní hry, dokumentace, slovníky, korpusy, grafy, rukopisy, zarovnání, odkazy, změny textu, notové zápisy...
- nástroje - sada XSLT pro převod na LaTeX, docx, EPUB, HTML

LMF

- *Lexical Markup Framework*,
<http://www.lexicalmarkupframework.org/>
- ISO-24613:2008
- jednotný model pro tvorbu lexikálních zdrojů
- důraz na strojové zpracování a rozšiřitelnost
- UML diagram pro lexikon
- jádro se základními informacemi + rozšíření pro různé oblasti
(morfologie, syntax, sémantika...)



Dictionary Writing Systems

- aplikace pro tvorbu slovníků (obvykle celý proces tvorby)
- propojení s dalšími aplikacemi (korpusy, analyzátory...)
- často vlastní
- komerční (IDM DPS, iLex, TLex, ABBYY Lingvo Content)
- *DEB (Dictionary Editor and Browser)*
 - ▶ platforma pro slovníkové aplikace
 - ▶ klient-server, základní knihovny, speciální moduly
 - ▶ DEBDict, DEBVisDic, Internetová jazyková příručka
 - ▶ <http://deb.fi.muni.cz>

[New Document Object Model] TshwaneLex - [Dictionary of Louisiana French.tdict]

Fichier Edition Vue Lemme Dictionnaire Format Outils Fenêtre Aide

Nouveau lemme Supprimer Inverser Références bilingues: sans

sanctuaire (*) sandale (*) sandwich (*) sang (*) sangle (*) sangler (*) sang-mêlé (*) sangsue (*) sani sans (*) sans-coeur (*) sans-joie (*) Santa Claus (*) santé (*) saoul saper [1] (*) saper [2] sapré (*) sans (*) sans-coeur (*) sani

Lemma: sans LemmaSign=sans,Modified=2009-02-23 20:15:20
 - Pronunciation: text: 'sɑ̃'
 - POSGroup: AutoNumber=1,PartOfSpeech=prep.

Sense: 1 AutoNumber=1
 - TE: TE=without
 - Example: Example=C'est bon quand tu peux danser sans musique.
 - Example: Example=On peut faire sans travailler le dimanche.
 - Combination: LemmaSign=sans cesse,Etymolo

Combination: LemmaSign=sans connaissance,
 - TE: TE=endless
 - TE: TE=ceaseless
 - Combination: LemmaSign=sans doute,Etymolo

Combination: LemmaSign=sans (que),Etymolo

Attributs (F1) **Attributs (F2)** Rechercher (F3) Incomplete

Lemma: sans
LemmaSign: sans
Comma:
Brackets:
Frequency: 0
Notes:

Pronunciation:
Audio: Parcourir...
Speaker:
[PCDATA]: sɑ̃
POSGroup:
LemmaSign:
PartOfSpeech: prep.

sans [sɑ̃] prep.
 1 without • C'est bon quand tu peux danser sans musique. It's good when you can dance without music. (EV) • On peut faire sans travailler le dimanche. We can do it without working on Sunday. (SL, An94) ■ sans cesse endless, ceaseless <Da84> ■ sans connaissance unconscious <Da84> ■ sans doute no doubt, without a doubt <Da84> ■ sans (que) a unless • Et on veillait le mort, bien sûr. On aurait jamais laissé le mort sans que quelqu'un soit là. And we waked the body, of course. We would've never left the body unless someone was there. (TB) b without • T'auras pas battu dans la salle sans il te fuit dehors. You wouldn't have fought in the dance hall without him throwing you out. (LA, An94) <LA, TB, An94, Da84> ■ ça va sans dire it goes without saying <Da84> <Loc: AV, EV, IB, IV, LA, LF, SL, TB, VM, An94, Da84, Gu00, Hl02, Wh83> [Admin]

sans-coeur [sɑ̃kœ̃r] n.
 1 heartless, cruel, pitiless person • Tu es rien qu'un sans-coeur. You're nothing but a cruel man. (SB)
 <Loc: SB, Da84, Di32> [Admin]

sans-joie [sɑ̃ʒwa] n.m.
 1 great blue heron
 <Loc: Lv68, Re31> [Admin]

Santa Claus [s̄d̄takl̄z, s̄tēkl̄z] n.prop.
 1 Santa Claus
 <Loc: AC, EV, IB, Lv68, Ph36> [Admin]

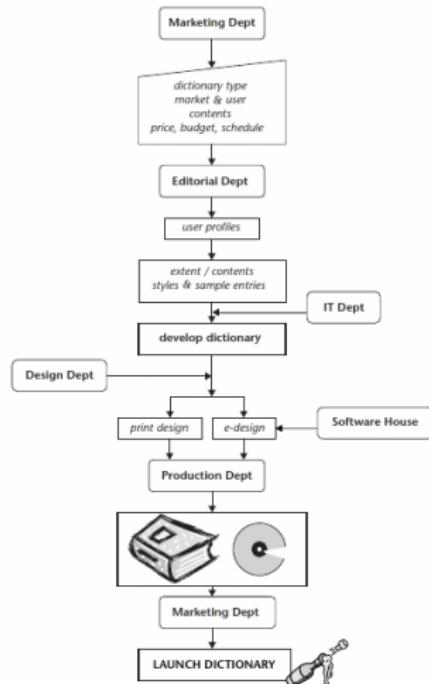
santé [s̄d̄tē] n.f.
 1 health • J'ai pas pu m'empêcher de marcher à lui. Je dis, "Il y a une question j'aimerais te demander. Quoi c'est tu fais pour ta santé?" Il dit, "Je vas au bal proche tous les soirs." I couldn't help but walk over to him. I said, "There's a question I'd like to ask you. What do you do for your health?" He said, "I go to the dance almost every night." (ch: La neige sur la couverture) ■ à votre santé to your health <Da84> ■ en bonne santé in good health <Da84> ■ en mauvaise santé in bad health <Da84>

Lexikální databáze

- podrobná strukturovaná jazyková databáze
 - ▶ (nyní obvykle) doklady z korpusu
 - ▶ gramatické údaje
 - ▶ valence, vzory
 - ▶ styl, užití, oblast...
 - ▶ vztahy mezi slovy
- podklad pro slovníky a výzkum
- *PraLeD* (Pražská Lexikální Databáze)
- *DANTE* (Database of ANalysed Texts of English)

Tvorba slovníku

- tvorba slovníků je drahá, náročná a trvá dlouho, konkurence
- B. T. Sue Atkins, Michael Rundell: *The Oxford Guide to Practical Lexicography*



Obsah slovníku

- **makrostruktura** – heslář (+předmluva, přílohy...)
- heslo¹ = lemma, entry term, heslové slovo, headword
 - ▶ obvykle nominativ sg., slovesa v infinitivu
 - ▶ části slov, spojení slov
- heslo² = heslová stat', entry
- **mikrostruktura** – struktura jednoho záznamu ve slovníku
 - ▶ kontrola pomocí softwaru
 - ▶ usnadnění orientace pro čtenáře

Elektronické slovníky

- více informací (CD, DVD, web)
 - ▶ místo pro zobrazení
- multimédia, vyhledávání, navigace, aktualizace
- delší vysvětlující články, odkazy na další zdroje
- zobrazování údajů podle profilu uživatele (časté operace)
- propojení s korpusy – ordnet.dk, DWDS.de...
- kombinace zdrojů, stahujeme data – Wordnik.com
- obsah vytvářený uživateli (90-9-1) – Wiktionary, slovnik.zcu.cz...
- Macmillan – přechod na digitální verzi
- posun od produktů ke službám