

# IB047

## Nástroje pro psaní slovníků

Pavel Rychlý

pary@fi.muni.cz

May 13, 2022

# Editor pro velké organizace

- správa uživatelů
- řízení přístupu
- předávání/schvalování

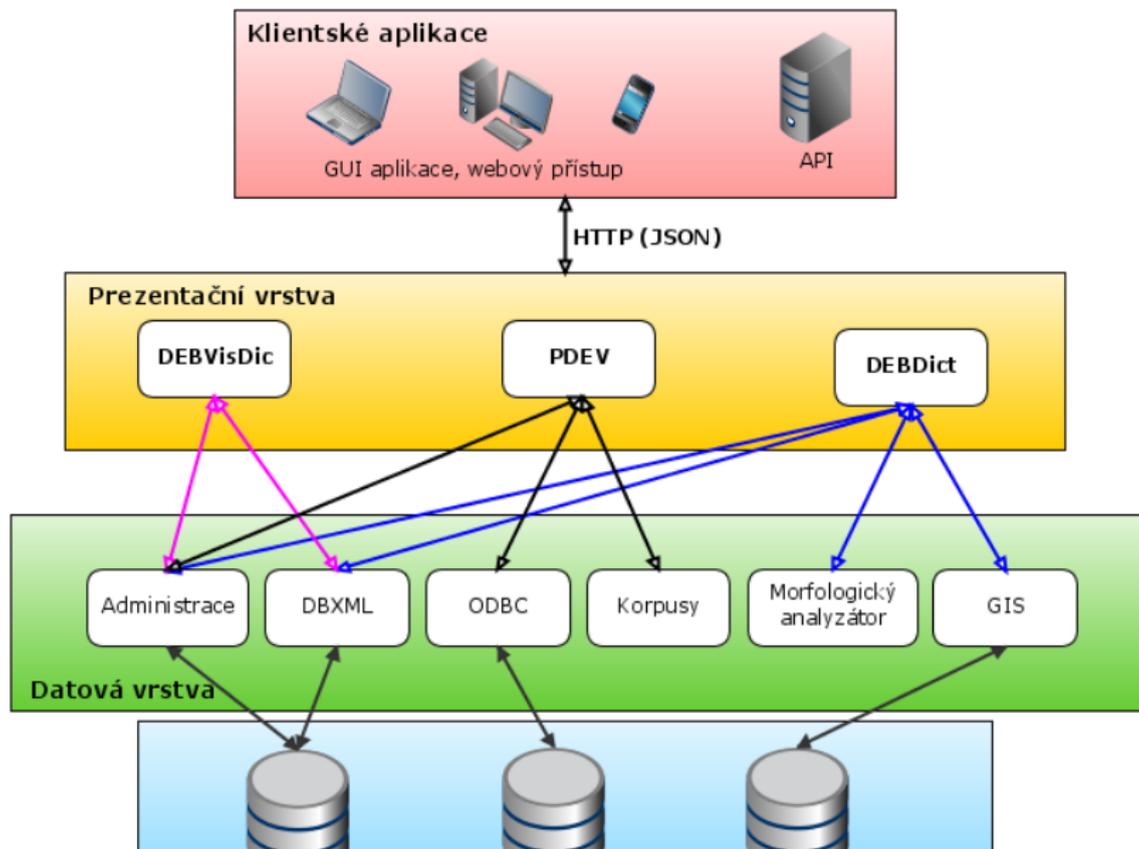
The screenshot displays the 'Entry Editor' application window. The title bar reads 'Entry Editor : (dps2 server)'. The interface is divided into several sections:

- Project Information:** Project: Wednesday, Headword: Wednesday, Senses: 1, Words: 74, Characters: 443.
- Navigation and Tools:** A menu bar with FILE, EDIT, CONFIG, TOOLS, and HELP. A toolbar contains icons for NEW, PRINT, SAVE, TEMPLATE, VERSIONS, and FIND.
- Left Panel:** Contains a search bar, a 'LOCAL STORE' section with 'ENTRY TOC', and a 'REMOTE STORE' section with a tree view showing folders like 'FIRSTLGP' and 'DAYS'.
- Central Panel:** Displays the dictionary entry for 'Wednesday'. The text includes: 'Wednesday ■ noun the day of the week before Thursday and following Tuesday. ■ adverb chiefly N. Amer. on Wednesday. ► (Wednesdays) on Wednesdays; each Wednesday. -ORIGIN OE *W[onac]r[ate]dnesdæg*, named after the Germanic god Odin, translation of late L. *Mercurii dies*.' The word 'Wednesday' is highlighted in blue.
- Right Panel:** Shows a morphological analysis tree for the highlighted word. The root node is 'DF' (the day of the week before Thursday and following Tuesday). It branches into 'ES' (a report goes before the councillors on Wednesday), 'EX' (they finish early on Wednesdays), 'ES' (as SY modifier /SY), and 'EX' (on a Wednesday morning). Further down, 'NLP' (DOHCLASS) Day is shown, followed by 'SET', 'POSG' (POG), and 'HSDICT' (LG chiefly GE N. Amer. /GE) on Wednesday.

## DEB – Dictionary Editor and Browser

- platforma pro vývoj slovníkových aplikací
  - všechna data ve formátu XML, Unicode
  - libovolná struktura, jakýkoliv jazyk
- architektura klient-server
- server
  - práce s daty, velká část funkcí
  - databázové úložiště
  - správa uživatelů, slovníků, spolupráce
  - rozděleno do modulů, spojování podle potřeb
- klient
  - omezená funkcionality
  - grafické nebo webové rozhraní

# Platforma DEB



- prohlížeč slovníků
- 7 slovníků češtiny pro veřejnost, další přístupné jen pro část uživatelů
- napojení na morfologický analyzátor
- data z externích zdrojů
- přes 900 uživatelů (podepsané prohlášení)

DEB Prohlížeč slovníků

všechny slovníky

- SSJ slovník spis. jaz. českého
- SSC slovník cizích slov
- SSČ slovník spis. češtiny
- SSS slovník českých synonym
- slm slov. fráze a idiomy
- slm neslov. fráze a idiomy
- PSJ příruční sl. jaz. českého
- všechny slovníky
- Český WordNet
- Concise Oxford English D.
- Oxford Dictionary of English
- Oxford Thesaurus of English
- Slovníkový slovník
- Komplexní slovník ruštiny
- Diderot
- Google
- Answers.com
- Wikipedia
- Seznam Encyklopedie
- CIA World Factbook
- mapa ČR
- morf. analyzátor ajka

kód Hledat  hledat i v definicích Nastavení

**ssjc** Slovník spisovného jazyka českého

**kód**  
-u m. (6. j. -u) (z fr.) odb. předpis pro převod jedné soustavy znaků pro sdělování zpráv do jiné takové soustavy; používat kódu; tajný k. známý jen určitému okruhu osob; telegrafní k. předpis pro převod elektrických, optických n. jiných signálů do soustavy jazykových znaků; **kódový** před. k. název; k-á zkratka

**kódovací**  
před. odb. týkající se kódování, sloužící ke kódování: k. soustava

**kódovati**  
ned. i dok. odb. (co) sestavovat, sestavit podle kódu: k. telegram

**kódový**  
v. kód

---

**SSC** Slovník spisovné češtiny

**kód**  
-u m <f>  
1. systém znaků pro přenos informace telegrafní, dálnopisný kód, jazykový kód,  
2. výp. tech. pravidla pro jednoznačné přiřazení významu k znakům n. signálům

**kódovat**  
ned. i dok. sestavovat, sestavit podle kódu kódovat zprávu,  
**kódovací** před. sloužící ke kódování, kódovací systém,

---

**psjc** Příruční slovník jazyka českého

## Příprava lexikální databáze češtiny v Ústavu pro jazyk český

**jazyk**  
 Zdroj pro heslář fsc+ssjc  
 Typ hesla jednosl. podstatné jméno  
 STAT. Sg/Pl 12792/3985 FRQ 16777 ARF 6122 Zdroj

SEZNAMY (rozbalit/sbalit)  
 SLOVOTVORBA  
 Derivovaná slova

Fundace/motivace

Defraz. lexémy

Zpracovatel vvesely |  
 Vytvořeno 2008-12-04 10:44 změněno 2009-09-14 12:26

**jazyk** Homonymie

Zdroj pro heslář fsc+ssjc  
 Typ hesla jednosl. Slovní druh/typ podstatné jméno  
 U zkratek: Plné znění zkratky  
 Pozn. k celému heslu

Uložit a zavřít Uložit Zavřít

**V1**  
 Původ definice: SSJČ *svalnatý velmi pohyblivý orgán v dutině ústní (u zvířat v tlamě, zobáku atd.); orgán chuti, mluvy*

**E1 k V1 Adj+SUBST** (rozbalit/sbalit)  
**E2 k V1 SUBST+Adj.** (rozbalit/sbalit)  
**E3 k V1 SUBST+Subst-gen** (rozbalit/sbalit)  
**E4 k V1 Subst+SUBST-gen** (rozbalit/sbalit)  
 vyplazování jazyka;  
 vyfíznutí jazyka;  
 špička jazyka, kořen jazyka

Pozn. k E4 zpracovávané substantivum je samo genitivním

**E5 k V1 SUBST+Prep+Subst/SUBST+Subst-ji**

Pozn. k E5 předložková příjmenek ke zpracovávanému substantivu

ZÁHLAVÍ ADMIN. VÝSL. PŮVOD DĚLENÍ ETYMOL. STAT.  
 EXPL. ÚJEMNÍ PRÍZNAK. ROBOVÝ PRÍZNAK. STYLOVÝ PRÍZNAK.  
 ZKR./EKVIVALENTY SOUSLOVÍ FRAZÉMY JINÉ VÍCESL. VÝRAZY VÍCESL. NEZAŘAZENO KOMP. VÍCESL. SLOVOTVORBA

Zavřít Sbalit seznamy Sbalit exempl. Duplikovat Zpět Pozn. Tisk NOVÉ DOKLADY DEF Náhled 1 2 Náhled 3 jazyk všec... Hledat

**jazyk : FRAZÉMY**

- + mit jazyk (ostrý) jako meč Dohledat Odkaz  
 Poznámka  
 - + mit jazyk jako na obrtliku Dohledat Odkaz  
 Poznámka  
 - + mit jazyk jako poleno Dohledat Odkaz  
 Poznámka  
 - + mlčí jako by /mu/ přimrzl jazyk Dohledat Odkaz  
 Poznámka

Uložit a zavřít Uložit Zavřít

- editace slovníku vzorů anglických sloves
- varianty také pro češtinu, italštinu a španělštinu

The screenshot displays the CPA Entry Manager interface. On the left is a list of verb entries with columns for the verb, frequency, and other metrics. The 'answer' entry is selected. On the right, the 'answer: CPA Patterns' window shows a list of patterns for the selected verb. Pattern 1 is selected, and its details are shown in the lower pane.

**CPA Entry Manager**

Entry	Filter	...	OEC	...	E
amuse	2	17444	4		
anaesthetize	2	60	3		
analyse	1	12828	4		
anger	2	7467	8		
angle	4	3189	2		
anglicize	2	122	1		
anchor	5	4693	4		
animate	3	4929	1		
anneal	1	221	5		
annex	3	2277	2		
annihilate	1	1831	1		
annotate	1	1015	9		
announce	4	92547	1		
annoy	2	28130	5		
annul	1	852	1		
anoint	1	1285	1		
answer	13	129214	9		
antagonize	1	782	8		
antedate	1	152	2		
anthologize	1	93	2		
anthropomorph...	1	80	3		
anticipate	2	20741	2		
ape	1	892	7		
apologize	1	17983	4		
apostrophize	1	16	7		
appal	1	106	1		
appeal	4	40303	4		

**answer: CPA Patterns**

Patterns for: **answer** Add Copy Corpora Preview Renumber Delete Close

Save Sample size Semantic class Aspectual class

- 1** **[[Human]] answer [NO OBJ] (that [CLAUSE] | [QUOTE])**  
[[Human]] says (that [CLAUSE] | [QUOTE]) in response to a question or statement by someone else
- 2** **[[Human]] answer [[Ask Activity]]**  
[SUB][Human]] says or writes something intended to provide relevant information in response to someone else's [OBJ][Ask Activity]
- 3** **[[Human]] answer [[Telephone]]**  
[SUB][Human]] speaks into [OBJ][Telephone] after it rings
- 4** **[[Human 1]] answer [NO OBJ] (to [[Human 2]] | to [[God]])**  
[SUB][Human]] has an obligation to account for his/her actions to [[Human 2 | God]]
- 5** **[[Human]] answer [[Mail]]**  
[SUB][Human]] writes a letter in response to [OBJ][Mail] from someone else
- 6** **[[Human]] answer [[Speech Act = Accusation]]**  
[[Human]] says or writes something intended to refute [[Speech Act = Accusation]]

**answer Pattern 1** show: Save Save & close Close Test

**subject** Human  Role  Lexset  Attr.

**verb form** answer

**object**  no object

**adverbial** add  no adverbial

**clausal**  optional |  to/INF [V]  -ING  that [CLAUSE]  WH- [CLAUSE]  [QUOTE]

**primary implicature** semantics  idiom

[[Human]] says (that [CLAUSE] | [QUOTE]) in response to a question or state:  idiom

Count: 13

Patterns: 1383 Verbs: 356

# TeDi – Terminologický slovník

- společný projekt s Fakultou výtvarných umění VUT
- glosář výtvarných pojmů
- multimediální prvky
- nově také Divadelní fakulta JAMU, Agronomická fakulta MU

The screenshot shows a web browser window titled "TeDi: editace hesla adresa (grafická, dedikační) - Seamonkey". The address bar contains the URL "https://apollo.fi.muni.cz:8010/teDi?action=edit&id=adresa\_g". The page content includes a form for editing a term with the following fields:

- Autor:** ID: **adresa\_(grafická\_dedikační)-11804343501**
- obor:** kresba-grafika
- heslo:** A table with two columns: "česky" and "anglicky". The "česky" cell contains "adresa (grafická, dedikační)" and the "anglicky" cell contains "address".
- varianty:** A table with two columns: "německy" and "francouzsky". The "německy" cell contains "Adresse f." and the "francouzsky" cell contains "adresse f.".
- styl. příznak:** standard, knižní
- definice:** součást značení díla, starých grafických listů obsahující jméno či obchodní označení vydavatele nákladu rytin, leptů atp. Trvale obsažena ve vlastním tisku.
- příklady:** (empty field)
- nadpojem:** značení díla

- editor slovníků typu WordNet
- samostatný modul pro každý jazyk (modifikace)
- použit pro tvorbu několika wordnetů
- poskytuje API – napojení externích aplikací
- možnost rozšíření a modifikací

The image displays three overlapping windows of the DEBVisDic application, each showing a different language's wordnet data for the same concept (ID: ENG20-06256978-n).

- English WordNet (Left):** Shows a list of related terms like 'cipher', 'cryptograph', 'code flag', etc. The selected entry is 'code:1, codification:2'. The definition is 'a set of rules or principles or laws (especially written ones)'. The domain is 'factotum'. The SUMO/MILO label is 'Obligation'. The hypernym is 'written communication:1, written language:1'. The eng\_derivative is 'codify:1'. The hyponym list includes 'Bushido:1', 'legal code:1', 'building code:1', 'dress code:1', 'fire code:1', 'omerta:1', 'sanitary code:1, health code:1', and 'Highway Code:1'.
- Greek WordNet (Middle):** Shows the Greek word 'κώδικας:2'. The definition is 'σύλλογος κανόνων ή αρχών ή νόμων γραπτών'. The hypernym is '[hyponym] γραπτή επικοινωνία:1, λόγος'. The stamp is '/'. The status bar shows 'Querying a dictionary is complete. Item(s): 30'.
- Korean WordNet (Right):** Shows the Korean word '교화'. The status bar shows 'Querying a dictionary is complete. Found 4 item(s). Item(s): 1'.

- univerzální editor slovníků
- slouží i k prezentaci
- cloud-based = klient v prohlížeči
- `www.lexonomy.eu`
- konfigurace obsahu (struktury) i prezentace
- integrace se Sketch Engine

- předgenerování z korpusu
- anotace
- posteditace

- multi-word expressions (MWE)
- collocatons
- thesaurus
- domains
- examples
- translations

# Examples

A good example must be:

- typical, exhibiting frequent and well-dispersed patterns of usage
- informative, helping to elucidate the definition
- readability
  - intelligible to learners,
  - avoiding gratuitously difficult lexis and structures, puzzling or distracting names, anaphoric references,
  - can be understood without access to the wider context.

# GDEX – Good Dictionary EXamples

- sentence length: 10 – 25 words, longer/shorter penalized
- word frequencies: non common words (top 17,000) penalized
- pronouns and anaphors penalized
- target collocation in the main clause preferred
- whole sentence: beginning with a capital letter and ending with .!?

- *usually spoken, business*
- domain annotation in corpus
- *only in plurals*
- condition specification + threshold
  - values of a structure attribute
  - subcorpus
  - query (tags)

```
=plurals  
HR plural  
Q1 [lempos="%s" & tag="NN2"]  
Q2 [lempos="%s" & tag="NN1"]  
RE -n$
```