

IB047

Nástroje pro psaní slovníků

Pavel Rychlý

pary@fi.muni.cz

May 12, 2025

Editory pro velké organizace

- správa uživatelů
- řízení přístupu
- předávání/schvalování

The screenshot shows the 'Entry Editor : (dps2 server)' application window. The main area displays the word 'Wednesday' with its definition: 'the day of the week before Thursday and following Tuesday'. Below this, there is a detailed description and etymology. On the left, there are navigation menus for 'LOCAL STORE' (with 'ENTRY TOC' selected) and 'REMOTE STORE' (listing categories like 'FIRSTLGP', 'FIRSTLGPE02', 'DAYS', and 'DAYSE02', with specific entries for 'today', 'Tuesday', 'washday', 'Wednesday', and 'weekday'). The top menu bar includes FILE, EDIT, CONFIG, TOOLS, and HELP. The right side of the interface contains various toolbars and a preview pane showing examples of the word's usage.

Project
Headword Wednesday
Senses 1
Words 74 Characters 443

FILE EDIT CONFIG TOOLS HELP

UNLOCK UPLOAD

LOCAL STORE ENTRY TOC

Wednesday noun

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 *Wōmacr̄dnesdæg*, named after the Germanic god Odin; translation of late L. *Mercurij dies*.

quick adminidm

REMOTE STORE

FIRSTLGP

FIRSTLGPE02

DAYS

DAYSE02

today

Tuesday

washday

Wednesday

weekday

XREF

DF the day of the week before Thursday and following Tuesday.

EX a report goes before the councillors on Wednesday

EX they finish early on Wednesdays

as modifier

EX on a Wednesday morning.

NLP

DOH CLASS Day

sel

POSG

POS

HSDICT

LG chiefly GE N. Amer. /GE

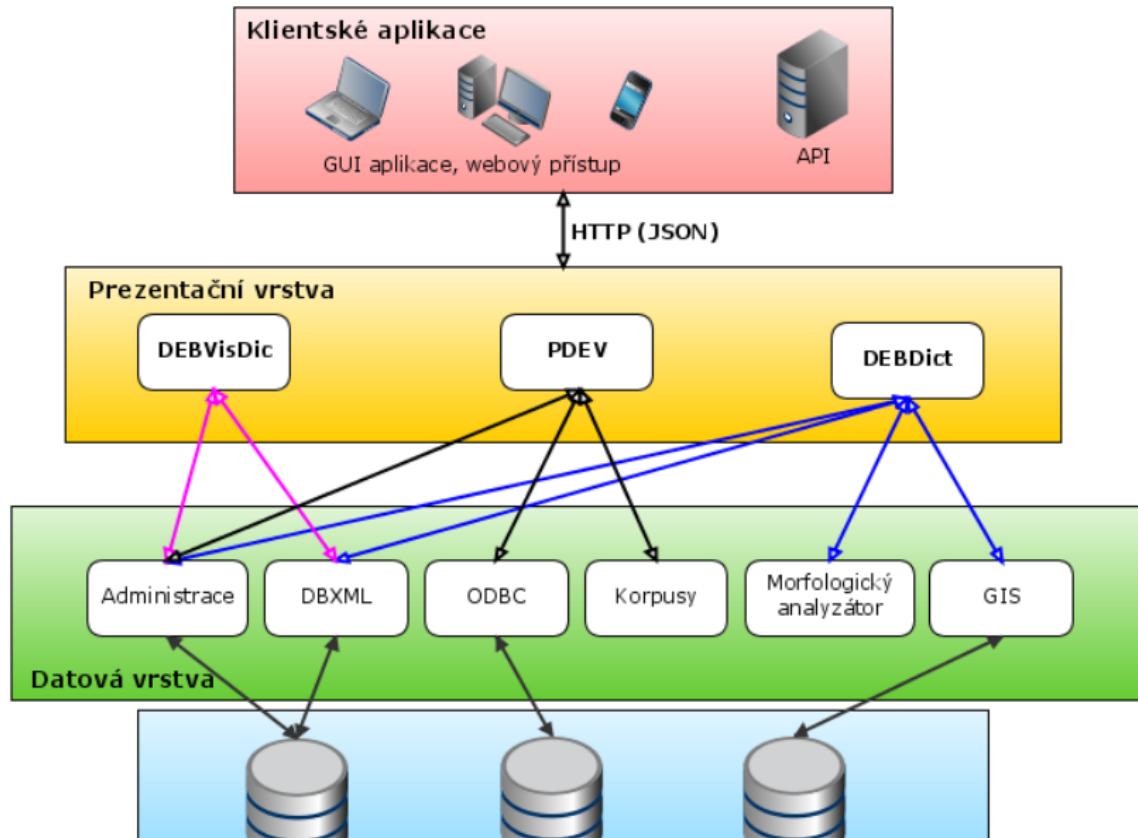
DF on Wednesday.

EX

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

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 kód; tajný k. známý jen určitému okruhu osob; telegrafní k. předpis pro převod elektrických, optických n. jiných signálů do soustavy jazykových znaků; **kódový** příd.: k. název; k. á zkratka

kódovací

příd. 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 příd. sloužící ke kódování, kódovací systém,

psjc Příruční slovník jazyka českého

← → ↻

Příprava lexikální databáze češtiny v Ústavu pro jazyk český

jazyk

Zdroj pro heslár fsc+ssjc
Typ hesla jednosl. podstatné jméno
STAT. Sg/Pl 12792/3985 FRQ 18777 ARF 6122 Zdroj

SEZNAMY (rozbalit/sbalit)
SLOVOTVORBA
Derivovaná slova

Fundace/motivace
Defraz. lexémy

jazyk

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

jazyk : ZÁHLAVÍ

Heslo **jazyk**
Zdroj pro heslár 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;
 výříznutí 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 nejdložkově předložkově připustitelné k zpracování následujícího substantivu

ZÁHLAVÍ ADMIN VYSL PŮVOD DĚLENÍ ETYMOL STAT
EXPR ÚZEMNÍ PRÍZNAK DOBOVÝ PRÍZNAK STYLOVÝ PRÍZNAK
ZKR./EKVIVALENTY SOUSLOV FRAZÉMY JINÉ VÍCESL. VÝRÁZY VÍCESL. NEZAŘAŽENO KOMP. VÍCESL. SLOVOTVORBA

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

jazyk : FRAZÉMY

Poznámka mit jazyk (ostřý) jako meč
Poznámka mit jazyk jako na obrtilku
Poznámka mit jazyk jako poleno
Poznámka mlčí jako /mu/ přímrzl jazyk
Poznámka

Uložit a zavřít Uložit Zavřít

PDEV (CPA)

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

The screenshot shows the CPA Entry Manager interface. On the left is a table of verb entries with columns for Entry, ID, OEC, and Count. The 'answer' entry is selected. On the right is a detailed pattern editor for the 'answer' pattern.

Patterns for: answer

Pattern ID	Description
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]] [SUBJ][Human] says or writes something intended to provide relevant information in response to someone else's [OBJ][Ask Activity]
3	[[Human]] answer [[Telephone]] [SUBJ][Human] speaks into [OBJ][Telephone] after it rings
4	[[Human 1]] answer [NO OBJ] {to [[Human 2]] to [[God]]} [SUBJ][Human] has an obligation to account for his/her actions to [[Human 2 God]]
5	[[Human]] answer [[Mail]] [SUBJ][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

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]
semantics

primary implicate: [[Human]] says {that [CLAUSE] | [QUOTE]} in response to a question or state
Count: 13

Patterns: 1383 Verbs: 356

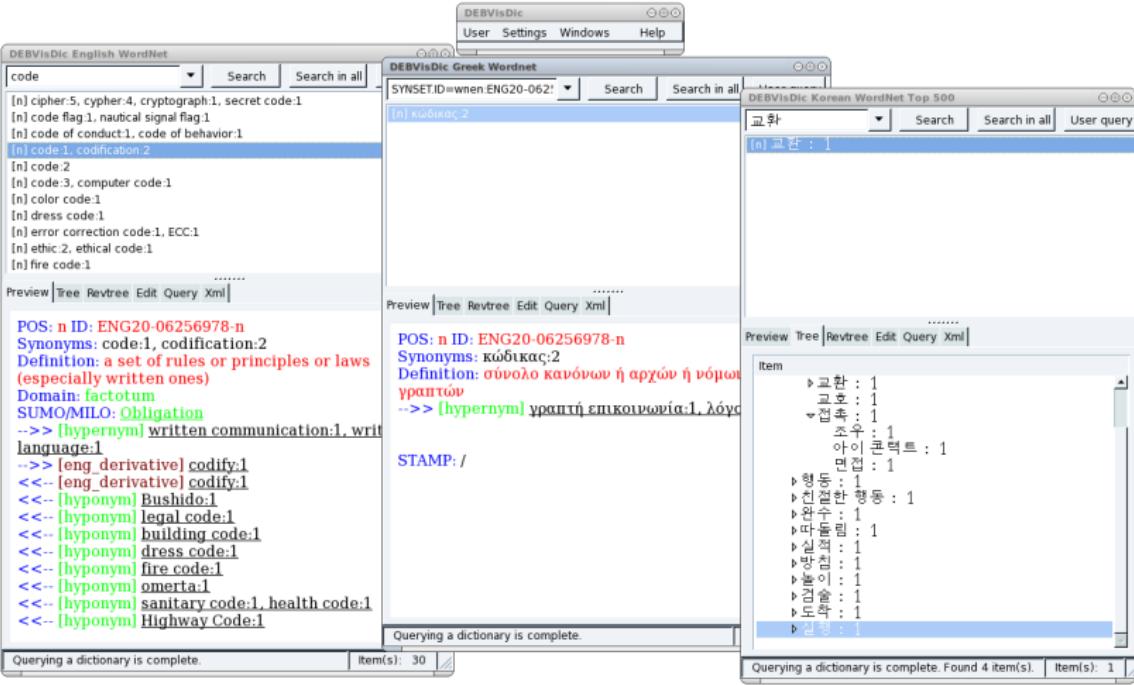
TeDi – Terminologický slovník

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

The screenshot shows a window titled "TeDi, editace hesla adresa (grafická, dedikační) - SeaMonkey". The window contains fields for various language translations and definitions. The "obor" dropdown is set to "kresba-grafika". The "heslo česky" field contains "adresa (grafická, dedikační)". The "anglicky" field contains "address". The "německy" field contains "Adresse f.". The "francouzsky" field contains "adresse f.". The "varianty" section has an empty input field and a "+" button. The "styl. příznak" dropdown is set to "standard, knižní". The "definice" section contains the text: "součást značení díla, starých grafických listů obsahující jméno či obchodní označení vydavatele nákladu rytin, leptů atp. Trvale obsažena ve vlastním tisku.". The "příklady" section has an empty input field and a "+" button. The "nadpojem" section contains "značení díla" and a "+" button. The "podpojem" section contains "např. pinxit, invenit, delineavit, incisit," and a "+" button.

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

DEBVisDic



Lexonomy

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

Budoucnost tvorby slovníků

- předgenerování z korpusu
- anotace
- posteditace

Informations from Corpora

- 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 .!?

Domains/usage

- *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$
```

Definitions by LLMs

Research by EKI on EKI Combined Dictionary 2024

- Estonian, 60 words
- Parts of speech: Nouns, adjectives, verbs, adverbs
- Words with 1, 2, 3, and 4 meanings included
- LLMS: Llama 3, GPT-4, GPT-3.5-turbo, **GPT-4o, Gemini 1.5 Pro, Claude 3 Sonnet**
- 21 respondents, experience in lexicography 3–43 years
(average = 19)

Definitions by LLMs

- 15 foreign words
- LLMs were more likely to produce meaning descriptions with higher usefulness rating if the word was a foreign word (average rating of usefulness for native words: 2.01; average rating of usefulness for foreign words: 2.3)
- Eight of the top ten words with the highest average usefulness rating were foreign words.

Definitions by LLMs

- General satisfaction: meaning descriptions for 83% of sample words were rated somewhat useful or very useful by lexicographers
- For 75% of test words the language used in meaning descriptions was assessed grammatically correct, 20% partially correct and 5% incorrect
- Given meanings were considered correct in 56% of cases, partially correct in 33% and incorrect in 10% of cases
- GPT-4o worked best for Estonian and had (slightly) higher average ratings than Gemini in all aspects studied
- Both models performed better with foreign words
- **LLMs provide a base that needs to be checked and adjusted accordingly**