

Databáze slovesných valenčních rámců

PLIN059

Mgr. Dana Hlaváčková, Ph.D.

Slovesná valence

- **slovesná valence** – schopnost slovesa vázat k sobě další lexikální jednotky (substantiva, adjektiva, adverbia, infinitiv jiného slovesa, vedlejší větu)
- schopnost je dána (2 přístupy)
 - gramaticky (gramatickými vlastnostmi slovesa) – *Vallex*
 - sémanticky (významem slovesa) – *VerbaLex*
- *pozn.* existuje také *valence substantiv či adjektiv*

Slovesná syntax – teoretická východiska

- **závislostní syntax** (Tesnièr)
 - doplnění slovesa – aktanty a cirkumstanty (= volná doplnění)
- **pádová gramatika** (Fillmore)
 - zavádí tzv. hloubkové pády (Agens, Patients ad.), sémantika
- v ČR zejména František Daneš (oba přístupy)
 - gramatické větné vzorce (GVV)
 - sémantické větné vzorce (SVV)
- později Petr Karlík (ÚČJ FF MU, směr Fillmore) a Jarmila Panevová (ÚFAL MFF UK, směr Tesnièr a FGP Petra Sgalla)

Valenční rámce

- formální záznam slovesné valence
- zachycují valenci
 - levostrannou (subjekt/podmět)
 - pravostrannou (objekt/předmět a další aktanty/argumenty/doplnění)
- bývají doplněny o sémantické informace – hloubkové pády/sémantické role/tématické role/funktory, příp. o další informace o slovesech

Valenční slovníky a databáze

- Svozilová N., Prouzová H., Jirsová A. – **Slovesa pro praxi. Valenční slovník nejčastějších českých sloves.** Praha: Academia, 1997. (tištěná publikace, elektronicky na webu ÚJČ AV ČR)
- **Vallex** – ÚFAL MFF UK, od r. 2002, webová aplikace a tištěná publikace
 - Lopatková, M., Kettnerová, V., Bejček, E., Vernerová, A., Žabokrtský, Z.: **Valenční slovník českých sloves VALLEX.** Praha: Karolinum, 2016.
 - popis viz <http://ufal.mff.cuni.cz/vallex>
 - prohlížení Vallexu 3.5 <http://ufal.mff.cuni.cz/vallex/3.5/>

Valenční slovníky a databáze

- **VerbaLex** – CZPJ FI MU (Hlaváčková, Horák)
 - webová aplikace
 - od r. 2004
 - proti Vallexu více zaměřen na sémantickou rovinu
 - bližší popis viz dizertační práce *Hlaváčková, D. Databáze slovesných valenčních rámců VerbaLex, 2008* (v ISu)

VerbaLex – cíl

- vytvořit rozsáhlou elektronickou databázi českých slovesných valenčních rámců
- zachytit valenci sloves na syntaktické i sémantické úrovni
- doplnit další relevantní informace o chování sloves v přirozeném kontextu

VerbaLex – stručná charakteristika

- začátek práce v roce 2004
- 15 anotátorů + 6 pracovníků CZPJ (softwarová podpora)
- zpracováno **10 596** slovesných lemmat
 - **výchozí zdroje**
 - **BRIEF** (1997, FI MU), 15 000 sloves, 50 000 povrchových valenčních rámců
 - **Czech WordNet** (2002–2004, Balkanet, FI MU), 1 359 valenčních rámců k 824 synsetům
 - **Vallex** (od 2002, UFAL MFF UK), Vallex 2.0 – 4 250 lemmat

VerbaLex – stručná charakteristika

- typické rysy VerbaLexu
- částečně inspirace z WordNetu
- slovesné lemma (variantní lemma) s číslem významu
- synonymické řady (tvořeny posloupností lemmat, např.: *jíst:1, požít(požívat):2*)
- syntaktická a sémantická rovina rámce
- základní a komplexní valenční rámec

Základní valenční rámec

- valenční doplnění na syntaktické úrovni (přímé a předložkové pády)
- valenční doplnění na sémantické úrovni (sémantické role)
- nejfrekventovanější idiomatická doplnění

Komplexní valenční rámec

- synonymie, číslování významů polysémnních sloves
- definice významu synonymické řady
- homonymie (číslování odlišných významů, př. *sladit*, *stát*)
- možnost tvoření pasiva + tranzitivnost, intranzitivnost
- slovesný vid (slovesa dokonavá, nedokonavá, obouvidá)
- sémantické třídy sloves
- způsob užití slovesa (základní, přenesené, idiomatické)
- reflexivita (refl. tantum, reciprocita, syntakt. refl., absol. synon.)
- doloženo konkrétními příklady

Základní valenční rámec

Synset: *jíst:1, požít(požívat):2*

Def: *přijímat potravu*

Subsynset: *jíst:1*

Sémantická role 1. úrovně

AG – agens

INS - instrument

obligatorní

Pozice slovesa

fakultativní

AG(kdo1;<person:1>;obl) **VERB** **SUBS**(co4;<food:1>;obl)**INS**(čím7;<cutlery:2>;opt)

*zájmenný výraz
s číslem pádu*

Sémantická role 2. úrovně

SUBS – substance

Komplexní valenční rámec – příklad

jíst:1(impf), požít:2(pf), požívat:2(impf)

definition: *přijímat potravu*

class: eat-39.1

passive: yes

jíst:1 ≈

-frame: **AG(kdo1;<person:1>;obl) VERB SUBS(co4;<food:1>;obl) INS(čím7;<cutlery:2>;opt)**

-example: *synovec jedl zmrzlinu (im pf)*

-example: *dcera jí polévku lžící (im pf)*

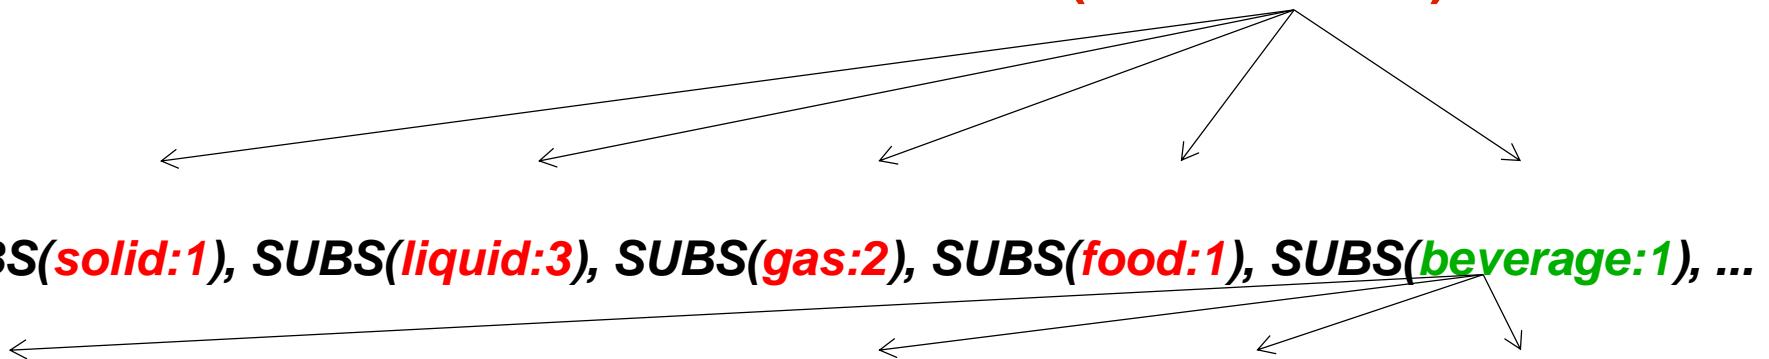
-synonym: požít:2, požívat:2

-use: prim

-reflexivity: no

Dvouúrovňové sémantické role

- **EuroWN vrcholová ontologie (Top-Ontology)** ► vrcholová hyperonyma EuroWN (63 prvků), entity 1., 2. a 3. řádu
- **Např.**: EuroWN Top-Ontology: entita 1. řádu ►
- **Substance** – ve VerbaLexu sémantická role **1. úrovně** ► **SUBS**
- **2. úroveň** – hyperonymum ► **substance:1** *definition - that which has mass and occupies space*
- **dvouúrovňová sémantická role** ► **SUBS(substance:1)**



milk:1, alcohol:1, chocolate:1, fruit juice:1, soft drink:1, coffee:1, tea:1, drinking water:1, ...

.hyponymické lexikální jednotky specifikující význam

(beverage:1 – definition – any liquid suitable for drinking)

Sémantické třídy sloves

- **Motivace:** sémantická klasifikace predikátů (Daneš, Grepl, Karlík), vztah sémantických rolí ve VerbaLexu k sémantickým třídám sloves
- **Východisko:**
- Beth Levin, *English Verb Classes and Alternations* –
- 48 základních sémantických tříd
- Martha Palmer, *VerbNet* – 82 základních sémantických tříd, celkem 395 podtříd
- české sémantické třídy – modifikovaný překlad, doplnění o další synonyma, vidové protějšky a prefigovaná slovesa,
- 82 základních sémantických tříd, celkem 258 podtříd, aktuálně seznam zahrnuje 11 241 sloves, z toho 6 393 různých lemmat

Použité softwarové nástroje

- Existující nástroje
- DEBDict – slovníky *SSČ*, *SSJČ*, *SČFI*, *SČS*
 - synonymie, definice významu synonymické řady, homonymie, možnost tvoření pasiva + tranzitivnost, intranzitivnost, slovesný vid, způsob užití slovesa, reflexivita
- Webové rozhraní *Bonito2*, *Word Sketch Engine*
 - korpusy SYN2000, ALL
 - ověřování valenčních doplnění a nejfrekventovanějších idiomatických doplnění, konkrétní příklady užití ve větách
- DEBVisDic
 - dodržení návaznosti VerbaLexu na Czech WordNet a Princeton WordNet, číslování významů

Použité softwarové nástroje

- **Nástroje upravené pro potřeby VerbaLexu**
- **Editor gVIM** – editace databáze, kontrola formálních chyb
- převody do formátů **xml, pdf a html** – formální podoba datové struktury databáze
- v současné době možnost zadávat data přes webový formulář

Dostupnost

- dostupnost:
 - <https://nlp.fi.muni.cz/verbalex/html2> (starší webové rozhraní, úplné informace)
 - <https://nlp.fi.muni.cz/verbalex/html3/> (novější webové rozhraní, neúplné informace)
 - v obou případech login: verbalex, heslo: cjbb85