

# PA153 Počítačové zpracování přirozeného jazyka

## 04 – Sémantika I (reprezentace lexikálního významu)

Karel Pala, Zuzana Nevěřilová

Centrum ZPJ, FI MU, Brno

17. října 2018

- 1 Lexikální význam
- 2 Slovníkové heslo
- 3 Nalezení významu v kontextu
  - Algoritmy lexikální desambiguace
- 4 Popis lexikálních významů pro ZPJ
  - Sémantické primitivy
  - Sémantické třídy
  - Sémantické vektory
- 5 Shrnutí

# Lexikální význam

lexikální význam (*lexical meaning*): izolovaný význam slova  
[Oxford Dictionaries, 2013]

- bez ohledu na význam **věty**, ve které se slovo nachází
- bez ohledu na **gramatické kategorie**

# Lexikální význam

lexikální význam (*lexical meaning*): izolovaný význam slova  
[Oxford Dictionaries, 2013]

- bez ohledu na význam **věty**, ve které se slovo nachází
- bez ohledu na **gramatické kategorie**

jiné významy: gramatický význam, význam slov a význam vět

# Lexikální význam

lexikální význam (*lexical meaning*): izolovaný význam slova  
[Oxford Dictionaries, 2013]

- bez ohledu na význam **věty**, ve které se slovo nachází
- bez ohledu na **gramatické kategorie**

jiné významy: gramatický význam, význam slov a význam vět

- *kuře – kuřata*
- *frekvence – kmitočet*
- Pan profesor *běží* na tramvaj. Geparď *běží* za kořistí.

# Lexikální forma a lexikální význam

**Lexikální jednotka** (lexical unit, LU) [Ziková, 2003]:

- reprezentována **lexikální formou**
- asociována s určitým **lexikálním významem**
- má určité **gramatické vlastnosti** (např. tranzitivní sloveso)
- může mít určité **pragmatické vlastnosti** (např. *já* je pokaždé někdo jiný)

# Lexikální forma a lexikální význam

**Lexikální jednotka** (lexical unit, LU) [Ziková, 2003]:

- reprezentována **lexikální formou**
- asociována s určitým **lexikálním významem**
- má určité **gramatické vlastnosti** (např. tranzitivní sloveso)
- může mít určité **pragmatické vlastnosti** (např. *já* je pokaždé někdo jiný)
  
- LU se stejným významem, ale jinou formou

# Lexikální forma a lexikální význam

**Lexikální jednotka** (lexical unit, LU) [Ziková, 2003]:

- reprezentována **lexikální formou**
  - asociována s určitým **lexikálním významem**
  - má určité **gramatické vlastnosti** (např. tranzitivní sloveso)
  - může mít určité **pragmatické vlastnosti** (např. *já* je pokaždé někdo jiný)
- 
- LU se stejným významem, ale jinou formou **synonymie** (např. šalina, tramvaj, šmirgl)
  - LU se stejnou formou, ale jiným významem



# Lexikální forma a lexikální význam

**Lexikální jednotka** (lexical unit, LU) [Ziková, 2003]:

- reprezentována **lexikální formou**
- asociována s určitým **lexikálním významem**
- má určité **gramatické vlastnosti** (např. tranzitivní sloveso)
- může mít určité **pragmatické vlastnosti** (např. *já* je pokaždé někdo jiný)
  
- LU se stejným významem, ale jinou formou **synonymie** (např. šalina, tramvaj, šmirgl)
- LU se stejnou formou, ale jiným významem **homonymie** (např. kolej)

## Kde najít informace o lexikálním významu?

Pro nás slovník/lexikon/lexikální databáze = soubor lexikálních jednotek (LU)

strojově čitelné slovníky = machine readable dictionaries



# Struktura slovníkového hesla

## bez

-u m. (6. j. -u)

1. *šeřík* (bot.): modrý, bílý b.; kytice bezu

2. *vysoký keř s květenstvím drobných nažloutlých květů, které dozrávají na podzim v drobné černé bobulky* (bezinky); *bez černý* (bot.): trást bez(em); [x] zůstat pod bezem *neprovdát se*; ob. expr. *jdi mi s tím na b. dej pokoj*; bot. rod *Sambucus*: b. černý; b. hroznatý

3. ob. *květ černého bezu*: vařit čaj z bezu; přen. *odvar z bezového květu*: pít teplý b. (Jir.)

- lexikální forma
- gramatické vlastnosti
- definice
- kolokace
- příklady užití
- odvozené lexikální formy (hnízdování)

## Kolokace jako slovníkové heslo

pevné kolokace: zakopaný pes, devíticásá kočka, slaměný vdovec, New York, křížem krážem, ad hoc

porušují princip kompozicionality  
samostatná slovníková hesla?

## Kolokace jako slovníkové heslo

pevné kolokace: zakopaný pes, devíticásá kočka, slaměný vdovec, New York, křížem krážem, ad hoc

porušují princip kompozicionality  
samostatná slovníková hesla?

v NLP se používá termín multiword expression (MWE)  
je důležité MWE identifikovat, např. pro strojový překlad:

- zamrzlé MWE: ad hoc
- pevné MWE: zakopaný pes, zakopaného psa, \*zakopaní psi, dejme tomu
- syntaktické anomálie: cobydup, coby dup, co by dup
- MWE s možnou přetržkou: více méně, více či méně
- MWE jako vzory (*patterns*): vzít <*někoho*> na hůl

Více informací v [Constant et al., 2017]

# Slovníkové definice a hyperonymie

## bez

-u m. (6. j. -u)

1. *šeřík* (bot.): modrý, bílý b.; kytice bezu
2. *vysoký keř s květenstvím drobných nažloutlých květů, které dozrávají na podzim v drobné černé bobulky* (bezinky); *bez černý* (bot.): trást bez(em); [x] zůstat pod bezem *neprovdát se*; ob. expr. *jdi mi s tím na b. dej pokoj*; bot. rod *Sambucus*: b. černý; b. hroznatý
3. ob. *květ černého bezu*: vařit čaj z bezu; přen. *odvar z bezového květu*: pít teplý b. (Jir.)

Definice pomocí **synonym**:

bez = šeřík

# Slovníkové definice a hyperonymie

## bez

-u m. (6. j. -u)

1. *šeřík* (bot.): modrý, bílý b.; kytice bezu
2. *vysoký keř s květenstvím drobných nažloutlých květů, které dozrávají na podzim v drobné černé bobulky (bezinky); bez černý* (bot.): trást bez(em); [x] zůstat pod bezem *neprovdát se*; ob. expr. *jdi mi s tím na b. dej pokoj*; bot. rod *Sambucus*: b. černý; b. hroznatý
3. ob. *květ černého bezu*: vařit čaj z bezu; přen. *odvar z bezového květu*: pít teplý b. (Jir.)

Definice pomocí **synonym**:

bez = šeřík

Definice **klasická**:

bez = vysoký keř s květenstvím drobných nažloutlých květů. . . [Havránek et al., 1960]

- genus proximum (nejbližší rod)
- differentia specifica (druhové rozdíly)

# Slovníkové definice a hyperonymie

## bez

-u m. (6. j. -u)

1. *šeřík* (bot.): modrý, bílý b.; kytice bezu
2. *vysoký keř s květenstvím drobných nažloutlých květů, které dozrávají na podzim v drobné černé bobulky (bezinky); bez černý* (bot.): trást bez(em); [x] zůstat pod bezem *neprovdát se*; ob. expr. *jdi mi s tím na b. dej pokoj*; bot. rod *Sambucus*: b. černý; b. hroznatý
3. ob. *květ černého bezu*: vařit čaj z bezu; přen. *odvar z bezového květu*: pít teplý b. (Jir.)

Definice pomocí **synonym**:

bez = šeřík

Definice **klasická**:

bez = **vysoký keř** s květenstvím drobných nažloutlých květů. . . [Havránek et al., 1960]

- **genus proximum (nejbližší rod)**
- **differentia specifica (druhé rozdíly)**



# Slovníkové definice a hyperonymie

## bez

-u m. (6. j. -u)

1. *šeřík* (bot.): modrý, bílý b.; kytice bezu

2. *vysoký keř s květenstvím drobných nažloutlých květů, které dozrávají na podzim v drobné černé bobulky (bezinky); bez černý* (bot.): trást bez(em); [x] zůstat pod bezem *neprovdát se*; ob. expr. *jdi mi s tím na b. dej pokoj*; bot. rod *Sambucus*: b. černý; b. hroznatý

3. ob. *květ černého bezu*: vařit čaj z bezu; přen. *odvar z bezového květu*: pít teplý b. (Jir.)

Definice pomocí **synonym**:

bez = šeřík

Definice **klasická**:

bez = vysoký keř s květenstvím drobných nažloutlých květů. . . [Havránek et al., 1960]

- genus proximum (nejbližší rod)
- differentia specifica (druhové rozdíly)

# Nalezení významu v kontextu

se znalostí lexikálního významu mnohdy nevystačíme  
⇒ je třeba znát kontext

# Nalezení významu v kontextu

se znalostí lexikálního významu mnohdy nevystačíme  
⇒ je třeba znát kontext

lexikální desambiguace (Word Sense Disambiguation)

funkce:  $(w, c) \rightarrow s$

- $w \in \mathcal{W}$  – množina slov
- $c \in \mathcal{C}$  – množina kontextů
- $s \in \mathcal{S}$  – množina významů

## Naivní Leskův algoritmus: list (SSJČ) [Lesk, 1986]

- 1 jeden ze základních orgánů rostlin, zprav. do plochy rozšířený a velmi různých tvarů; lupen: kaštanový, dubový, javorový l.; velký, malý l.; drobné listy borůvčí; široké listy lip; zelné listy; fíkový l., přen. (ve výtv. dílech) jeho zpodobení zakrývající ohanbí, jednání ap. věcně něco zastírající;
- 2 kniž. a nář. listí: svěžím listem zalesklo se habří (Jir.); stromy obalily se listem (Něm.)
- 3 kus papíru čtyřúhelníkového tvaru, zprav. určený k psaní, tisku ap.: sešit o 24 listech; titulní l. v knize; l. pergamenu; cyklus grafických listů; její duše je nepopsaný l. (kniž.) nemá zkušenosti; zpívat, hrát přímo z listu z notového partu bez cvičení; ...
- 4 kniž. a zast. dopis, psaní: zalepený, zapečetěný l.; otevřený l.; veřejný, osobní l.; listy Jana Nerudy; hist. opovědný, odporný, výhostní l.; církv. apoštolský, pastýřský l. provolání, výzva papeže, biskupa
- 5 úřední listina o něčem svědčící, k něčemu opravňující: rodný, domovský (dř.), oddací, úmrtní l.; výuční, živnostenský l.; odběrní, dodací l.; nákladní l.; záruční, zástavní l.; vůdčí l. (dř.) řidičský

## Naivní Leskův algoritmus: vstup

Ještě lepším řešením by bylo vydat se evropskou cestou: zbavit se úvěrů bez zodpovědnosti dlužníka a rozvinout systém financí založený na zástavních *listech*, jako jsou německé Pfandbriefe.



## Naivní Leskův algoritmus: vstup

Ještě lepším řešením by bylo vydat se evropskou cestou: zbavit se úvěrů bez zodpovědnosti dlužníka a rozvinout systém financí založený na zástavních *listech*, jako jsou německé Pfandbriefe.



{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

## Naivní Leskův algoritmus

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

1:{a, borůvčí, dílo, do, drobný, dubový, fíkový, javorový, jeden, jednání, kaštanový, lípa, lupen, malý, ohanbí, orgán, plocha, rostlina, rozšířený, různý, široký, tvar, věčně, velký, velmi, . . . }

2:{habří, listí, obalit, se, strom, svěží, zalesknout}

3:{bez, být, cvičení, cyklus, čtyřúhelníkový, dnes, duše, grafický, hráč, hrát, jeden, jeho, jiný, k, karta, kniha, který, kus, mít, mluvit, něco, notový, o, obrátit, on, padat, papír, part, pergamen, popsaný, přímo, psaní, ruka, se, sešit, situace, souhrn, štěstí, tvar, určený, v, tisk, titulní, z, . . . }

4:{apoštolský, biskup, dopis, Jan, Neruda, odporný, opovědný, osobní, otevřený, papež, pastýřský, svolání, psaní, veřejný, výhostní, výzva, zalepený, zapečetěný}

5:{dodací, domovský, k, kniha, listina, nákladní, něco, o, odběrní, oddací, opravňující, průkaz, pozemkový, rodný, řidičský, svědčící, úmrtní, úřední, vůdčí, výuční, záruční, zástavní, živnostenský}

# Naivní Leskův algoritmus

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

1: {a, borůvčí, dílo, do, drobný, dubový, fíkový, javorový, jeden, jednání, kaštanový, lípa, lupen, malý, ohanbí, orgán, plocha, rostlina, rozšířený, různý, široký, tvar, věčně, velký, velmi, ... }

2: {habří, listí, obalit, se, strom, svěží, zalesknout}

3: {bez, být, cvičení, cyklus, čtyřúhelníkový, dnes, duše, grafický, hráč, hrát, jeden, jeho, jiný, k, karta, kniha, který, kus, mít, mluvit, něco, notový, o, obrátit, on, padat, papír, part, pergamen, popsaný, přímo, psaní, ruka, se, sešit, situace, souhrn, štěstí, tvar, určený, v, tisk, titulní, z, ... }

4: {apoštolský, biskup, dopis, Jan, Neruda, odporný, opovědný, osobní, otevřený, papež, pastýřský, svolání, psaní, veřejný, výhostní, výzva, zalepený, zapečetěný}

5: {dodací, domovský, k, kniha, listina, nákladní, něco, o, odběrní, oddací, opravňující, průkaz, pozemkový, rodný, řidičský, svědčící, úmrtní, úřední, vůdčí, výuční, záruční, zástavní, živnostenský}



# Naivní Leskův algoritmus

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

1: {a, borůvčí, dílo, do, drobný, dubový, fíkový, javorový, jeden, jednání, kaštanový, lípa, lupen, malý, ohanbí, orgán, plocha, rostlina, rozšířený, různý, široký, tvar, věčně, velký, velmi, ... }

2: {habří, listí, obalit, se, strom, svěží, zalesknout}

3: {bez, být, cvičení, cyklus, čtyřúhelníkový, dnes, duše, grafický, hráč, hrát, jeden, jeho, jiný, k, karta, kniha, který, kus, mít, mluvit, něco, notový, o, obrátit, on, padat, papír, part, pergamen, popsaný, přímo, psaní, ruka, se, sešit, situace, souhrn, štěstí, tvar, určený, v, tisk, titulní, z, ... }

4: {apoštolský, biskup, dopis, Jan, Neruda, odporný, opovědný, osobní, otevřený, papež, pastýřský, svolání, psaní, veřejný, výhostní, výzva, zalepený, zapečetěný}

5: {dodací, domovský, k, kniha, listina, nákladní, něco, o, odběrní, oddací, opravňující, průkaz, pozemkový, rodný, řidičský, svědčící, úmrtní, úřední, vůdčí, výuční, záruční, zástavní, živnostenský}

# Naivní Leskův algoritmus

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

1: {a, borůvčí, dílo, do, drobný, dubový, fíkový, javorový, jeden, jednání, kaštanový, lípa, lupen, malý, ohanbí, orgán, plocha, rostlina, rozšířený, různý, široký, tvar, věčně, velký, velmi, ... }

2: {habří, listí, obalit, se, strom, svěží, zalesknout}

3: {bez, být, cvičení, cyklus, čtyřúhelníkový, dnes, duše, grafický, hráč, hrát, jeden, jeho, jiný, k, karta, kniha, který, kus, mít, mluvit, něco, notový, o, obrátit, on, padat, papír, part, pergamen, popsaný, přímo, psaní, ruka, se, sešit, situace, souhrn, štěstí, tvar, určený, v, tisk, titulní, z, ... }

4: {apoštolský, biskup, dopis, Jan, Neruda, odporný, opovědný, osobní, otevřený, papež, pastýřský, svolání, psaní, veřejný, výhostní, výzva, zalepený, zapečetěný}

5: {dodací, domovský, k, kniha, listina, nákladní, něco, o, odběrní, oddací, opravňující, průkaz, pozemkový, rodný, řidičský, svědčící, úmrtní, úřední, vůdčí, výuční, záruční, zástavní, živnostenský}

# Naivní Leskův algoritmus

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

1: {a, borůvčí, dílo, do, drobný, dubový, fíkový, javorový, jeden, jednání, kaštanový, lípa, lupen, malý, ohanbí, orgán, plocha, rostlina, rozšířený, různý, široký, tvar, věčně, velký, velmi, ... }

2: {habří, listí, obalit, se, strom, svěží, zalesknout}

3: {bez, být, cvičení, cyklus, čtyřúhelníkový, dnes, duše, grafický, hráč, hrát, jeden, jeho, jiný, k, karta, kniha, který, kus, mít, mluvit, něco, notový, o, obrátit, on, padat, papír, part, pergamen, popsaný, přímo, psaní, ruka, se, sešit, situace, souhrn, štěstí, tvar, určený, v, tisk, titulní, z, ... }

4: {apoštolský, biskup, dopis, Jan, Neruda, odporný, opovědný, osobní, otevřený, papež, pastýřský, svolání, psaní, veřejný, výhostní, výzva, zalepený, zapečetěný}

5: {dodací, domovský, k, kniha, listina, nákladní, něco, o, odběrní, oddací, opravňující, průkaz, pozemkový, rodný, řidičský, svědčící, úmrtní, úřední, vůdčí, výuční, záruční, zástavní, živnostenský}

# Naivní Leskův algoritmus

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

1: {a, borůvčí, dílo, do, drobný, dubový, fíkový, javorový, jeden, jednání, kaštanový, lípa, lupen, malý, ohanbí, orgán, plocha, rostlina, rozšířený, různý, široký, tvar, věčně, velký, velmi, ... }

2: {habří, listí, obalit, se, strom, svěží, zalesknout}

3: {bez, být, cvičení, cyklus, čtyřúhelníkový, dnes, duše, grafický, hráč, hrát, jeden, jeho, jiný, k, karta, kniha, který, kus, mít, mluvit, něco, notový, o, obrátit, on, padat, papír, part, pergamen, popsaný, přímo, psaní, ruka, se, sešit, situace, souhrn, štěstí, tvar, určený, v, tisk, titulní, z, ... }

4: {apoštolský, biskup, dopis, Jan, Neruda, odporný, opovědný, osobní, otevřený, papež, pastýřský, svolání, psaní, veřejný, výhostní, výzva, zalepený, zapečetěný}

5: {dodací, domovský, k, kniha, listina, nákladní, něco, o, odběrní, oddací, opravňující, průkaz, pozemkový, rodný, řidičský, svědčící, úmrtní, úřední, vůdčí, výuční, záruční, zástavní, živnostenský}

## Naivní Leskův algoritmus

Ještě lepším řešením by bylo vydat se evropskou cestou: zbavit se úvěrů bez zodpovědnosti dlužníka a rozvinout systém financí založený na zástavních *listech*, jako jsou německé Pfandbriefe.

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

$$D_1 = \{a\}$$

$$D_2 = \{se\}$$

$$D_3 = \{bez, být, se\}$$

$$D_4 = \{\}$$

$$D_5 = \{zástavní\}$$

## Naivní Leskův algoritmus

Ještě lepším řešením by bylo vydat se evropskou cestou: zbavit se úvěrů bez zodpovědnosti dlužníka a rozvinout systém financí založený na zástavních *listech*, jako jsou německé Pfandbriefe.

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

$$D_1 = \{a\}$$

$$D_2 = \{se\}$$

$$D_3 = \{bez, být, se\}$$

$$D_4 = \{\}$$

$$D_5 = \{zástavní\}$$

kus papíru čtyřúhelníkového tvaru, zprav. určený k psaní, tisku ap. ...

# Naivní Leskův algoritmus

Ještě lepším řešením by bylo vydat se evropskou cestou: zbavit se úvěrů bez zodpovědnosti dlužníka a rozvinout systém financí založený na zástavních *listech*, jako jsou německé Pfandbriefe.

{a, bez, by, být, cesta, dlužník, dobrý, evropský, finance, jako, ještě, německý, rozvinout, řešení, se, systém, úvěr, vydat, založený, zástavní, zbavit, zodpovědnost}

$$D_1 = \{a\}$$

$$D_2 = \{se\}$$

$$D_3 = \{bez, být, se\}$$

$$D_4 = \{\}$$

$$D_5 = \{zástavní\}$$

úřední listina o něčem svědčící, k něčemu opravňující

# WSD založené na metodách strojového učení

[Yarowsky, 1995]

- 1 stanovit význam u pevných kolokací (ručně nebo ze slovníku)  
obrátit list (list:3), živnostenský list (list:5), . . .
- 2 iterativně zjistit další kolokace  
kopie (živnostenského listu) → kopie oddacího listu (list:5)
- 3 opakovat, dokud desambiguované množiny nepřestanou narůstat



# WSD založené na metodách strojového učení [Yarowsky, 1995]

- 1 stanovit význam u pevných kolokací (ručně nebo ze slovníku)  
obrátit list (list:3), živnostenský list (list:5), ...
- 2 iterativně zjistit další kolokace  
kopie (živnostenského listu) → kopie oddacího listu (list:5)
- 3 opakovat, dokud desambiguované množiny nepřestanou narůstat

Algoritmus natrénovaný na obecném korpusu je použitelný na dalších textech.

# Slabiny WSD

$(w, c) \rightarrow s$

- $w \in \mathcal{W}$  – množina slov
- $c \in \mathcal{C}$  – množina kontextů
- $s \in \mathcal{S}$  – množina významů

# Slabiny WSD

$(w, c) \rightarrow s$

- $w \in \mathcal{W}$  – množina slov
- $c \in \mathcal{C}$  – množina kontextů
- $s \in \mathcal{S}$  – množina významů

Všechny algoritmy WSD závisejí na inventáři a popisu významů.

# Slabiny WSD

$(w, c) \rightarrow s$

- $w \in \mathcal{W}$  – množina slov
- $c \in \mathcal{C}$  – množina kontextů
- $s \in \mathcal{S}$  – množina významů

Všechny algoritmy WSD závisejí na inventáři a popisu významů.

Kolik významů má slovo *list*?

- SSJČ: 8
- SSČ: 6
- Slovník českých synonym: 4
- Český WordNet: 9

# WSD nebo WSD


Algoritmy, které nepočítají s pevným inventářem významů, jen s kontextem:

Word Sense *Discrimination*  
nebo  
Word Sense Induction

# WSD nebo WSI

Algoritmy, které nepočítají s pevným inventářem významů, jen s kontextem:

## Word Sense Discrimination nebo Word Sense Induction



# Komponentová analýza (*Componential analysis*)

= popis významů slov pomocí množiny sémantických rysů (primitiv), které jsou buď přítomny, nebo nepřítomny, nebo irelevantní pro daný význam:

- muž = +HUMAN +ADULT +MALE
- žena = +HUMAN +ADULT -MALE
- chlapec = +HUMAN -ADULT +MALE
- batole = +HUMAN -ADULT ±MALE

[Katz and Fodor, 1963] a [Bierwisch, 1971]

# Komponentová analýza (Componential analysis) I

označení	popis	příklad
T	tempus, čas	den, rok, leden, soumrak
L	locus, místo	dům, chrám, světadíl, břeh
BYT	bytost	víla
HUM	člověk	střežda, rada, bača
ANIM	zvíře	pes, slon, velbloud
PLANT	rostlina	strom, kosatec
QUA	vlastnost	nespokojenec, povýšenec + HUM
FEN	fenomén	úkaz, zázrak
ENT	entita	protiklad, argument
OBJ	objekt, předmět	stůl, krb, ale i dům (OBJ + L)



# Komponentová analýza (Componential analysis) II

označení	popis	příklad
INF	informace	telefonát, článek, vzkaz
EMO	emoce	cit, radost, strach, neklid, úsměv
INS	instrument, nástroj	nůž, šíp hřeben
MACH	stroj, aparát, zařízení	počítač
PROC	proces	zážeh, postup, pokrok
MOT	pohyb	běh, let, pád
AKT	aktivita, činnost	boj, odboj, příchod
MAT	materiál	hlína, dřevo
BP	část těla (body part)	prst, krk
ORG	organizace, instituce	vláda

# Sémantické třídy

= skupiny slov, která sdílejí určitý sémantický rys

# Sémantické třídy

= skupiny slov, která sdílejí určitý sémantický rys

obratlovec – savec – šelma – psovitá šelma – pes – pudl – trpasličí pudl

# Sémantické třídy

= skupiny slov, která sdílejí určitý sémantický rys

obratlovec – savec – šelma – psovité šelma – pes – pudl – trpasličí pudl

taxonomie, hierarchie tříd

# Sémantické třídy, Porfyriův strom

*Supreme genus:*

**Substance**

*Differentiae:*

**material**

**immaterial**

*Subordinate genera:*

**Body**

**Spirit**

*Differentiae:*

**animate**

**inanimate**

*Subordinate genera:*

**Living**

**Mineral**

*Differentiae:*

**sensitive**

**insensitive**

*Proximate genera:*

**Animal**

**Plant**

*Differentiae:*

**rational**

**irrational**

*Species:*

**Human**

**Beast**

*Individuals:*

**Socrates**


**Plato**

**Aristotle**

**etc.**

# Sémantické třídy, sémantické sítě, odvozování

# Sémantické třídy, sémantické sítě, odvozování



WordNet (Princeton WordNet, PWN) – lexikální síť

- původně nástroj k ověření teorie o uspořádání lidské paměti (G. A. Miller, od r. 1985)
- počítačově dobře zpracovatelný zdroj informací o významech slov a vztazích mezi významy [Fellbaum, 1998]
- jednotkou je synonymická řada (synonymical set, synset)
- synsety jsou spojeny relacemi:
  - ▶ hyperonymie/hyponymie: vůz, automobil – dodávka
  - ▶ holonymie/meronymie (part of, member of): vůz, automobil – tlumič; orchestr – houslista
  - ▶ near-antonym: den – noc
  - ▶ odvození: velikost – velký
- slovní druhy: substantiva, adjektiva, verba, adverbia



# WordNet

angličtina: PWN (117 tis. synsetů)

# WordNet

angličtina: PWN (117 tis. synsetů)

projekty EuroWordNet (angličtina + holandština, italština, španělština, němčina, francouzština, čeština, estonština)

- ILI - InterLingual Index
- Top Ontology (63 kategorií)
- Base Concepts

# WordNet

angličtina: PWN (117 tis. synsetů)

projekty EuroWordNet (angličtina + holandština, italština, španělština, němčina, francouzština, čeština, estonština)

- ILI - InterLingual Index
- Top Ontology (63 kategorií)
- Base Concepts

projekty (BalkaNet: bulharština, čeština, rumunština, řečtina, srbština, turečtina), při kterých vznikají wordnety pro další jazyky, koordinátorem databází je Global WordNet Association (GWA)

# WordNet

angličtina: PWN (117 tis. synsetů)

projekty EuroWordNet (angličtina + holandština, italština, španělština, němčina, francouzština, čeština, estonština)

- ILI - InterLingual Index
- Top Ontology (63 kategorií)
- Base Concepts

projekty (BalkaNet: bulharština, čeština, rumunština, řečtina, srbština, turečtina), při kterých vznikají wordnety pro další jazyky, koordinátorem databází je Global WordNet Association (GWA)

současný český W.: 28 tis. synsetů

# WordNet není jediný

Ontologie = explicitní specifikace sdílené konceptualizace

- firemní o.
- všeobecné o. SUMO/MILO (Suggested Upper Merged Ontology, Mid-Level Ontology)
- common sense o. ConceptNet

# Sémantické vektory

sémantické vektory: charakteristika jednotlivých slov a frází pomocí vektoru reálných čísel

nutná podmínka: distribuční sémantika

„a word is characterized by the company it keeps“

J.R.Firth

# Sémantické vektory

jeden vektor popisuje jedno slovo

# Sémantické vektory

jeden vektor popisuje jedno slovo

jedno slovo odpovídá jedné dimenzi

vektor popisuje kontext (n-gramy v okolí slova)

1	2	3	4	5
koupit	jíst	řídít	jablko	auto

hruška = (0.9,1,0,1,0)

pomeranč = (1,1,0,0.5,0)

náklad'ák = (0.8,0,1,0.3,0.9)



# Sémantické vektory

jeden vektor popisuje jedno slovo

jedno slovo odpovídá jedné dimenzi

vektor popisuje kontext (n-gramy v okolí slova)

1	2	3	4	5
koupit	jíst	řídít	jablko	auto

hruška = (0.9,1,0,1,0)

pomeranč = (1,1,0,0.5,0)

nákladník = (0.8,0,1,0.3,0.9)

příliš mnoho dimenzí a příliš prázdný prostor (řídke matice)

→ redukce dimenzí, vnoření slov (word embeddings)

word2vec – jeden ze způsobů vnoření (kromě n-gramů používá také skip-gramy, počet dimenzí 50–300)

pro trénování sémantických vektorů potřebujeme větší korpusy (> 10 milionů)

# Shrnutí

gramatika	slovní druh, gramatické kategorie
syntax	větný člen
sémantika	sémantická třída

# Shrnutí

gramatika    slovní druh, gramatické kategorie

syntax      větný člen

sémantika    **sémantická třída**

popis lexikálního významu:

- pro uživatele jazyka: slovníky
- pro počítačové programy: specializované zdroje (sém. rysy, ontologie, ...), vektorový popis

# Shrnutí

gramatika    slovní druh, gramatické kategorie

syntax      větný člen

sémantika    **sémantická třída**

popis lexikálního významu:

- pro uživatele jazyka: slovníky
- pro počítačové programy: specializované zdroje (sém. rysy, ontologie, ...), vektorový popis

rozlišení lexikálního významu:

- pro uživatele jazyka: číslo významu
- pro počítačové programy: WSD, vzdálenost mezi koncepty

# Odkazy I



Bierwisch, M. (1971).

On classifying semantic features.

In M. Bierwisch, K. E. H., editor, *Progress in Linguistics*, pages 27–50.  
Mouton.



Constant, M., Eryiğit, G., Monti, J., van der Plas, L., Ramisch, C.,  
Rosner, M., and Todirascu, A. (2017).

Multiword Expression Processing: A Survey.

*Computational Linguistics*, 0(ja):1–92.



Fellbaum, C. (1998).

*WordNet: An Electronic Lexical Database (Language, Speech, and  
Communication)*.

The MIT Press.

Published: Hardcover.

## Odkazy II



Goddard, C. (2011).

*Semantic Analysis: A Practical Introduction.*

Oxford Textbooks in Linguistics. Oxford University Press.



Havránek, B. et al. (1960).

*Slovník spisovného jazyka českého (Dictionary of Written Czech, SSJČ).*

Academia, Praha, 1st edition.

electronic version, created in the Institute of Czech Language, Czech Academy of Sciences Prague in cooperation with Faculty of Informatics, Masaryk University Brno.



Katz, J. and Fodor, J. (1963).

The structure of a semantic theory.

*Language*, (39):170–210.

## Odkazy III



Lesk, M. (1986).

Automatic sense disambiguation using machine readable dictionaries: how to tell a pine cone from an ice cream cone.

In *Proceedings of the 5th annual international conference on Systems documentation*, SIGDOC '86, pages 24–26, New York, NY, USA. ACM.



Oxford Dictionaries (2013).

lexical meaning. Oxford Dictionaries.  
online.

<http://oxforddictionaries.com/definition/english/lexical-meaning> (accessed October 03, 2013).



Véronis, J. (2004).

Hyperlex: Lexical cartography for information retrieval.

In *Computer Speech and Language: Special Issue on Word Sense Disambiguation*, page 23.

# Odkazy IV



Yarowsky, D. (1995).

Unsupervised word sense disambiguation rivaling supervised methods.  
In *Proceedings of the 33rd annual meeting on Association for Computational Linguistics*, ACL '95, pages 189–196, Stroudsburg, PA, USA. Association for Computational Linguistics.



Ziková, M. (2003).

Současný český jazyk: Tvoření slov.  
online.

[http://www.phil.muni.cz/cest/lide/zikova/CJA009\\_1.rtf](http://www.phil.muni.cz/cest/lide/zikova/CJA009_1.rtf)  
(accessed October 03, 2013).