

# PA153 Počítačové zpracování přirozeného jazyka

## 04 – Sémantika I

### (reprezentace lexikálního významu)

Karel Pala, Zuzana Nevěřilová

Centrum ZPJ, FI MU, Brno

18. listopadu 2013

- 1 Lexikální význam
- 2 Slovníkové heslo
- 3 Nalezení významu v kontextu
- 4 Popis lexikálních významů pro ZPJ
  - Sémantické primitivy
  - Sémantické třídy
  - Teorie prototypů
- 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. Gepard *běží* za kořistí.

## └ Lexikální význam

## └ 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

- *kule* = *kuřata*
- *frekvence* = *kmitočet*
- Pan profesor běží na tramvaj. Gepard běží za kočkou.

slova kuře a kuřata mají tentýž lexikální význam, ale rozdílný gramatický (singulár, plurál)

frekvence a kmitočet jsou různá slova, která mají tentýž lexikální (i gramatický a dokonce i další) význam

běžet má stejný význam, přestože si představíme celkem jinou činnost (styl, rychlosť, terén)

# 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?

Slovník/lexikon/lexikální databáze = soubor lexikálních jednotek (LU)

# Kde najít informace o lexikálním významu?

Slovník/lexikon/lexikální databáze = soubor lexikálních jednotek (LU)

Slovníky:

- jednojazyčné výkladové
- překladové
- současného jazyka (synonym, zkratek, rýmů ... )
- terminologické
- historické
- etymologické
- speciální (frekvenční, retrográdní, valenční)
- ...

strojově čitelné slovníky = machine readable dictionaries (MRD)



# 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.): trášt bez(em); [x] zůstat pod bezem *neprovdat 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)

## PA153 Zpracování přirozeného jazyka

## └ Slovníkové heslo

## └ Struktura slovníkového hesla

## Struktura slovníkového hesla

**bez**

n. n. (š. j. -)

1. jednoduchý neadýk, když je vytvořena

2. vzdálený kód z hlediska dvojíhoch nezávislých květů, které dlejí se podél v obou dvojích

květů (květ) / bez květu (ne, tisk květu); [š] základ podle hlediska využití v ohledech jiných květů

Nejčastěji lze vidět květy, když je květ v květu, jinak v květu

K. a. bez květu květ v květu, jinak v květu květu; pr. např. k. (š.)

## • ležákové forma

## • gramatické vlastnosti

## • definice

## • kolokace

## • příklady užití

## • odvozené ležákové formy (Inžidování)

Ukázka je ze SSJČ, kde není žádná odvozená forma, ale v SSČ je bezový a bezinka. Pro jiná slova je v SSČ mnohem více odvozených forem: květ, květen, květena, květák, květenství, květina, květináč, květinářka, květinářství

## Kolokace jako slovníkové heslo

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

porušují princip kompozicionality  
samostatná slovníková hesla?

# Kolokace jako slovníkové heslo

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

porušují princip kompozicionality  
samostatná slovníková hesla?

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

- pevné MWE: zakopaný pes
- vzory: vzít <*někoho*> na hůl

# 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 *neprovdat 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.): trášt bez(em); [x] zůstat pod bezem *neprovdat 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.): trášt bez(em); [x] zůstat pod bezem *neprovdat 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.): trášt bez(em); [x] zůstat pod bezem *neprovdat 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.): trášt bez(em); [x] zůstat pod bezem *neprovdat 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)

hyperonymie

# 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.): trášt bez(em); [x] zůstat pod bezem *neprovdat 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)

## hyperonymie

## kulhati

ned. (1. j. -ám, rozk. -ej, přech. přít. -aje)

1. chodit tak, že váha těla se nepřenáší stejnouměrně na obě nohy, levou nohu

## troponymie

## PA153 Zpracování přirozeného jazyka

## └ Slovníkové heslo

## └ Slovníkové definice a hyperonymie

## Slovnikové definice a hyperonymie

**bez**

n. n. (š. j. -)

1. jednotlivý mazdý, když je v kytice bez

2. výslovy kuf z hlediska drobných nářečníckých květů, které dlejítej na podzem v drobné části

bukové květiny; bez červen (ros., růž. kořen); [k] zlata pod bukem nevadí se ohně jich má a tisíce

bukovou květinou žlutou. V červnu je bukovec

3. a. bez červené květy včetně jeho větví a bukovek květu; při ledy k. (k.)

## Definice klasická:

**kulhati**

adverbium významu výkrov, pro spěch

4. obzde rok, že výkrov květů neplatí; například na období květu

## hyperonymie

Definice pomocí **synonym**:

bez = šéfik

tropomytie

- genitiv proximum (nejblíže rod)
- differentia specifica (druhové rozdíly)

klasické slovníkové heslo vyžaduje pro porozumění aspoň nějakou znalost jazyka, tudíž je pro počítačové zpracování neúplné

## Nalezení významu v kontextu

někdy (ve skutečnosti velmi často) jen se znalostí lexikálního významu nevystačíme

⇒ je třeba znát kontext

# Nalezení významu v kontextu

někdy (ve skutečnosti velmi často) jen se znalostí lexikálního významu 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: kočka (SSJČ) [Lesk, 1986]

- ① malá kočkovitá šelma, chovaná v domácnostech, na venkově zvl. pro hubení myší; kočka domácí (zool.); šedivá, černá, tříbarevná k.; hladká srst kočky; k. mňouká, přede; k. číhá na myš; k. chytá ptáky; angorská k.; být falešný, úlisný jako k.; přen. expr. je to k. falešník; to děvče je k. lichotné, úlisné; [x] jsou na sebe jako pes a k. nenávidí se...
- ② malá n. středně velká šelma s hustým kožichem; zool. rod *Felis*: k. plavá; k. divoká; k. domácí
- ③ samice kočkovité šelmy vůbec; rysí k.; lví k.; expr. každá kočkovitá šelma vůbec (tygr, levhart aj.)
- ④ ob. kožišina na límci, kolem krku n. ramen
- ⑤ kocovina (Haš.)
- ⑥ věc připomínající někt. vlastnost u kočky: bot. velký trs ostřic vystupující z rašeliníště (na blatech); tech. pojízdný vozík jeřábu se zdvihacím ústrojím
- ⑦ druh důtek; devítiocasá k.

## Naivní Leskův algoritmus: vstup

Aminokyselina DL-methionin okyseluje moč, čímž chrání močové ústrojí psů i koček (důležitá vlastnost zvláště u kastrovaných jedinců).

## Naivní Leskův algoritmus: vstup

Aminokyselina DL-methionin okyseluje moč, čímž chrání močové ústrojí psů i koček (důležitá vlastnost zvláště u kastrovaných jedinců).

{aminokyselina, DL-methionin, okyselovat, moč, čímž, chránit, močový, ústrojí, pes, i, důležitý, vlastnost, zvláště, u, kastrovaný, jedinec}

## Naivní Leskův algoritmus: vstup

Aminokyselina DL-methionin okyseluje moč, čímž chrání močové ústrojí psů i koček (důležitá vlastnost zvláště u kastrovaných jedinců).

{aminokyselina, DL-methionin, okyselovat, moč, čímž, chránit, močový, ústrojí, pes, i, důležitý, vlastnost, zvláště, u, kastrovaný, jedinec}

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

1: {a, angorský, být, černý, číhat, děvče, domácí, domácnost, expresivně, falešník, falešný, hladký, hubení, chovaný, chytat, jako, kočkovitý, lichotný, malý, mňoukat, myš, na, nenávidět, pes, pro, přeneseně, příst, pták, se, srst, šedivý, šelma, to, tříbarevný, úlisný, v, venkov, zoologicky, zvláště}

2: {divoký, domácí, Felis, hustý, kožich, malý, nebo, plavý, rod, s, středně, šelma, velký, zoologicky}

:

6: {bláto, botanicky, jeřáb, na, některý, ostřice, pojízdný, připomínající, rašelinště, s, technicky, trs, u, ústrojí, věc, velký, vozík, vlastnost, vystupující, z, zdvihací}

7: {devítiocasá, druh, důtky}

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

1: {a, angorský, být, černý, číhat, děvče, domácí, domácnost, expresivně, falešník, falešný, hladký, hubení, chovaný, chytat, jako, kočkovitý, lichotný, malý, mňoukat, myš, na, nenávidět, pes, pro, přeneseně, příst, pták, se, srst, šedivý, šelma, to, tříbarevný, úlisný, v, venkov, zoologicky, zvláště}  
2: {divoký, domácí, Felis, hustý, kožich, malý, nebo, plavý, rod, s, středně, šelma, velký, zoologicky}

:

6: {bláto, botanicky, jeřáb, na, některý, ostřice, pojízdný, připomínající, rašelinště, s, technicky, trs, u, ústrojí, věc, velký, vozík, vlastnost, vystupující, z, zdvihací}

7: {devítiocasá, druh, důtky}

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

1: {a, angorský, být, černý, číhat, děvče, domácí, domácnost, expresivně, falešník, falešný, hladký, hubení, chovaný, chytat, jako, kočkovitý, lichotný, malý, mňoukat, myš, na, nenávidět, pes, pro, přeneseně, příst, pták, se, srst, šedivý, šelma, to, tříbarevný, úlisný, v, venkov, zoologicky, zvláště}

2: {divoký, domácí, Felis, hustý, kožich, malý, nebo, plavý, rod, s, středně, šelma, velký, zoologicky}

:

6: {bláto, botanicky, jeřáb, na, některý, ostřice, pojízdný, připomínající, rašelinště, s, technicky, trs, u, ústrojí, věc, velký, vozík, vlastnost, vystupující, z, zdvihací}

7: {devítiocasá, druh, důtky}

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

1: {a, angorský, být, černý, číhat, děvče, domácí, domácnost, expresivně, falešník, falešný, hladký, hubení, chovaný, chytat, jako, kočkovitý, lichotný, malý, mňoukat, myš, na, nenávidět, pes, pro, přeneseně, příst, pták, se, srst, šedivý, šelma, to, tříbarevný, úlisný, v, venkov, zoologicky, zvláště}

2: {divoký, domácí, Felis, hustý, kožich, malý, nebo, plavý, rod, s, středně, šelma, velký, zoologicky}

:

6: {bláto, botanicky, jeřáb, na, některý, ostřice, pojízdný, připomínající, rašelinště, s, technicky, trs, u, ústrojí, věc, velký, vozík, vlastnost, vystupující, z, zdvihací}

7: {devítiocasá, druh, důtky}

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

1: {a, angorský, být, černý, číhat, děvče, domácí, domácnost, expresivně, falešník, falešný, hladký, hubení, chovaný, chytat, jako, kočkovitý, lichotný, malý, mňoukat, myš, na, nenávidět, pes, pro, přeneseně, příst, pták, se, srst, šedivý, šelma, to, tříbarevný, úlisný, v, venkov, zoologicky, zvláště}

2: {divoký, domácí, Felis, hustý, kožich, malý, nebo, plavý, rod, s, středně, šelma, velký, zoologicky}

:

6: {bláto, botanicky, jeřáb, na, některý, ostřice, pojízdný, připomínající, rašelinště, s, technicky, trs, u, ústrojí, věc, velký, vozík, vlastnost, vystupující, z, zdvihací}

7: {devítiocasá, druh, důtky}

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

$$D_1 = \{\text{pes}, \text{zvláště}\}$$

$$D_2 = \{\}$$

$$D_3 = \{\}$$

$$D_4 = \{\}$$

$$D_5 = \{\}$$

$$D_6 = \{\text{u}, \text{ústrojí}, \text{vlastnost}\}$$

$$D_7 = \{\}$$

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

$D_1 = \{\text{pes}, \text{zvláště}\}$

$D_2 = \{\}$

$D_3 = \{\}$

$D_4 = \{\}$

$D_5 = \{\}$

$D_6 = \{\text{u}, \text{ústrojí}, \text{vlastnost}\}$

$D_7 = \{\}$

# Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec, kastrovaný, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvláště}

$$D_1 = \{\text{pes}, \text{zvláště}\}$$

$$D_2 = \{\}$$

$$D_3 = \{\}$$

$$D_4 = \{\}$$

$$D_5 = \{\}$$

$$D_6 = \{\text{u}, \text{ústrojí}, \text{vlastnost}\}$$

$$D_7 = \{\}$$

věc připomínající někt. vlastnost u kočky: bot. velký trs ostřic vystupující z rašeliníště (na blatech); tech. pojízdný vozík jeřábu se zdvihami ústrojím

# PA153 Zpracování přirozeného jazyka

## └ Nalezení významu v kontextu

### └ Naivní Leskův algoritmus

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedinec,  
kastrovaný, mot, možný, okyselovat, pes, u, ústrojí, vlastnost, zvláště}  
 $D_1 = \{\text{pes}, \text{zvláště}\}$   
 $D_2 = \{\}$   
 $D_3 = \{\}$   
 $D_4 = \{\}$   
 $D_5 = \{\}$   
 $D_6 = \{\text{u}, \text{ústrojí}, \text{vlastnost}\}$   
 $D_7 = \{\}$   
vč. připomínající některé vlastnosti u kožky: bot. velký tri estifick vystupujici  
z ralefinitet (na blatech); tach. pojizdný vozek ježába se zdívacím  
ústrojím

Naivní L. algoritmus určil, že význam slova kočka v uvedené větě je 6. Je to spíš náhoda podpořená tím, že u významů 1 a 6 v SSJČ také nejvíce textu.

Vylepšené verze L. algoritmu některá slova nepočítají, přidávají slovům váhy (např. pomocí TF-IDF), zohledňují vzdálenost od desambiguovaného slova

# 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 *kočka*?

- SSJČ: 7
- SSČ: 2
- PSJČ: 10
- Slovník českých synonym: 4
- Český WordNet: 3

# PA153 Zpracování přirozeného jazyka

## └ Nalezení významu v kontextu

### └ Slabiny WSD

#### 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 závisí na inventáři a popisu významů.

Kolik významů má slovo kočka?

- SSJČ: 7
- SSČ: 2
- PSJČ: 10
- Slovník českých synonym: 4
- Český WordNet: 3

Leskův a. je jednoduchý i ve svých pokročilejších verzích, zajímavý algoritmus nabídl [Yarowsky, 1995]. Jde o a. strojového učení, kdy se v prvním průchodu určí kolokace, které naprostě jistě souvisejí s konkrétním významem slova. V dalších průchodech se vypočítávají další slova, která signalizují konkrétní význam slova.

## WSD nebo WSD


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

Word Sense *Discrimination*

# WSD nebo WSD

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

## Word Sense *Discrimination*



[Véronis, 2004]

## Komponentová analýza (*Componential analysis*)

= popis významů slov pomocí množiny sémantických rysů (primitiv), které jsou buď přítomny, nebo nepřítomny, nebo irrelevantní 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	strejda, 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 – psovitá šelma – pes – pudl – trpasličí pudl

taxonomie, hierarchie tříd

# Sémantické třídy, Porfyriův strom

*Supreme genus:*



*Differentiae:*

*Subordinate genera:*

*Differentiae:*

*Subordinate genera:*

*Differentiae:*

*Proximate genera:*


*Differentiae:*

*Species:*

*Individuals:*

# Sémantické třídy, sémantické sítě, odvozování

# Sémantické třídy, sémantické sítě, odvozování



# Sémantické sítě

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
  - ▶ troponymie: šeptat – mluvit
  - ▶ 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, srbská, 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, srbská, 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, MIld-Level Ontology)
- common sense o. ConceptNet

# Ontologie a datové formáty (ontologické jazyky)

- predikátová logika 1. řádu a rozšíření
- Rodina KIF (Knowledge Interchange Format)
- Rodina RDF (Resource Description Framework), „jazyky sémantického webu“: RDF, RDFS, OWL, DAML

# Teorie prototypů: co je to ptáček?

# Teorie prototypů: co je to ptáček?



Aitchison, 2003 in [Goddard, 2011]

# Teorie prototypů

E. Rosch dokázala, že lidé uvažují o vlastnostech třídy jako o vlastnostech typického zástupce třídy.

# Teorie prototypů

- E. Rosch dokázala, že lidé uvažují o vlastnostech třídy jako o vlastnostech typického zástupce třídy.
- t. prototypů se uplatňuje v popisu typických situací (rámce, skripty)

## Teorie prototypů

E. Rosch dokázala, že lidé uvažují o vlastnostech třídy jako o vlastnostech typického zástupce třídy.

t. prototypů se uplatňuje v popisu typických situací (rámce, skripty)  
vzdálenost mezi koncepty: židle je víc *nábytek* než sporák

## 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, prototypy)

# 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, prototypy)

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.



Fellbaum, C. (1998).

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

The MIT Press.

Published: Hardcover.



Goddard, C. (2011).

*Semantic Analysis: A Practical Introduction*.

Oxford Textbooks in Linguistics. Oxford University Press.

## Odkazy II



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](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).