

# PA153 Počítačové zpracování přirozeného jazyka

## 04 – Sémantika I (reprezentace lexikálního významu)

Karel Pala, Zuzana Nevěřilová

Centrum ZPJ, FI MU, Brno

1. listopadu 2020

- 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**

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

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, rychlost, 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. *šmirgl* je expresivní označení pro *tramvaj*)

Lexikální vztahy:

- LU se stejným významem, ale jinou formou **synonymie** (např. šalina, tramvaj, šmirgl)
- LU se stejnou formou, ale jiným významem **homonymie** (např. kolej) nebo **polysémie** (např. ucho)

# Kde najít informace o lexikálním významu?

Slovník/lexikon = soubor lexikálních jednotek (LU)

Slovníky:

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



## PA153 Zpracování přirozeného jazyka

## └ Lexikální význam

## └ Kde najít informace o lexikálním významu?

## Slovníky:

- výkladové
- příkladové
- současného jazyka (synonym, zkratka, rjmů ...)
- terminologické
- historické
- etymologické
- speciální (frekvenční, retrográdní, valenční)
- ...

Na tomto místě zmiňujeme slovníky jen jako prostředky pro popis lexikálního významu. Více o slovnících, jejich druzích a vytváření slovníků vyučuje předmět *IB047 Úvod do korpusové lingvistiky a počítačové lexikografie*.

# Struktura slovníkového hesla

## bez

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

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

2. *vyšoký keř s květenstvím drobných nažloutlých květů, které dozrávají na podzim v drobné černé bobulky* (bezinky); *bez černý* (bot.): trásta 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
- pragmatické vlastnosti
- definice
- kolokace
- příklady užití
- odvozené lexikální formy

# 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

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 stejnoměrně na obě nohy, levou nohu*

troponymie



# 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 rašeliniště (na blatech); tech. pojízdný vozík jeřábu se zdvihacím ústrojím
- 7 druh důtek; devítiočasá k.

## 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}

## Leskův algoritmus: naivní

{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, rašeliniště, s, technicky, trs, **u**, **ústrojí**, věc, velký, vozík, **vlastnost**, vystupující, z, zdvihací}

**7:** {devítiocasá, druh, důtky}

## Leskův algoritmus: naivní

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

$$D_1 = \{\text{pes, zvláště}\}$$

$$D_2 = \{\}$$

$$D_3 = \{\}$$

$$D_4 = \{\}$$

$$D_5 = \{\}$$

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

$$D_7 = \{\}$$

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

## PA153 Zpracování přirozeného jazyka

## └─ Nalezení významu v kontextu

## └─ Leskův algoritmus: naivní

## Leskův algoritmus: naivní

{aminokyselina, což, DL-methionin, důležitý, chránit, i, jedínce, kastrovany, moč, močový, okyselovat, pes, u, ústrojí, vlastnost, zvířítě}

$D_1 = \{\text{pes, zvířítě}\}$

$D_2 = \{\}$

$D_3 = \{\}$

$D_4 = \{\}$

$D_5 = \{\}$

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

$D_7 = \{\}$

více připomínající nákt. vlastnost u kočky: bot, velký trs ostříc vystupující z rástliniček (na blátech); tech. pojízdný vozík jízdu se zdvíhacím 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 nejvíc textu.

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

## 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; devítiočasá k.

# 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

$(w, c) \rightarrow s$ 

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

Všechny algoritmy WSD závisí na inventáři a popisu významů.

Kolik významů má slovo ločka?

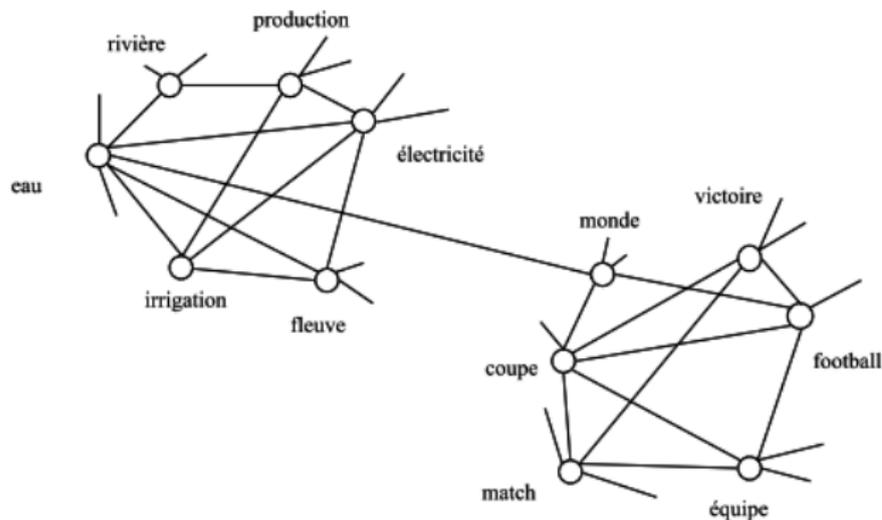
- SSJČ: 7
- SSČ: 2
- PSJČ: 10
- Slovník českých synonym: 4
- Český WordNet: 3

Leskův a. je jednoduchý i ve svých pokročilejších verzích, zajímavý algoritmus nabídl [Yarowsky, 1995]. Jde o alg. strojového učení, kdy se v prvním průchodu určí kolokace, které naprosto 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:

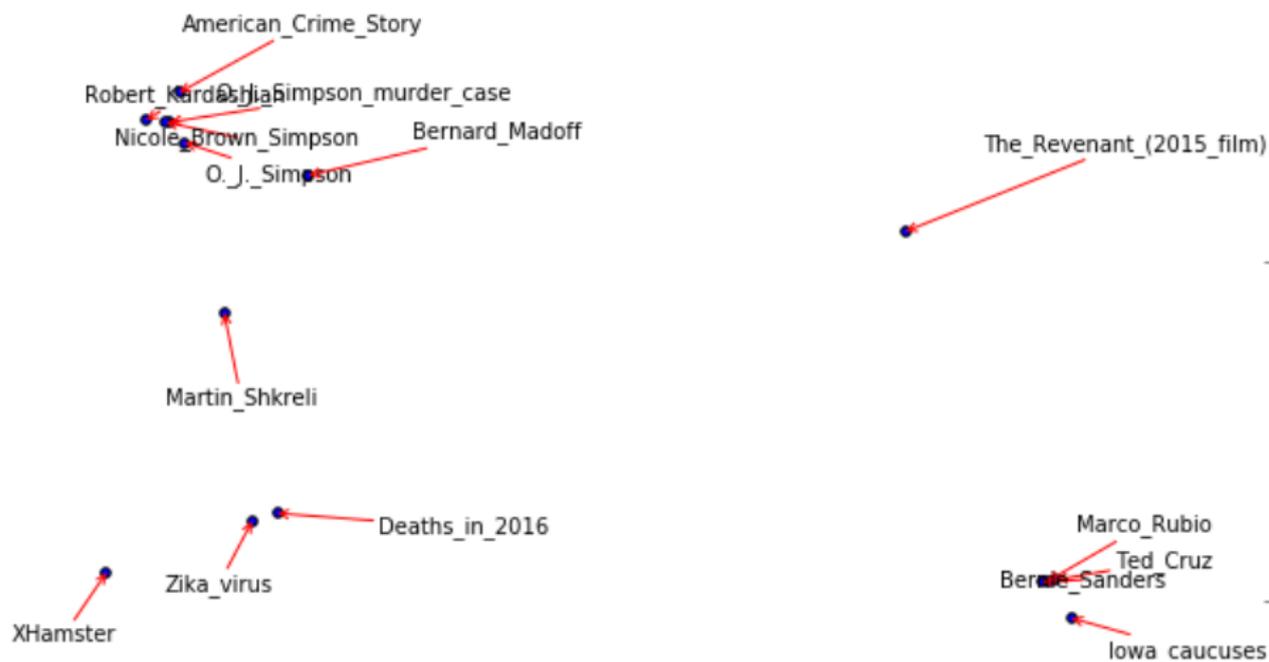
## Word Sense Discrimination



[Véronis, 2004]

# Word Sense Discrimination

Algoritmy, které nepočítají s pevným inventářem významů, jen s kontextem: **word embeddings**



# Komponentová analýza (Componential analysis)

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

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

# 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

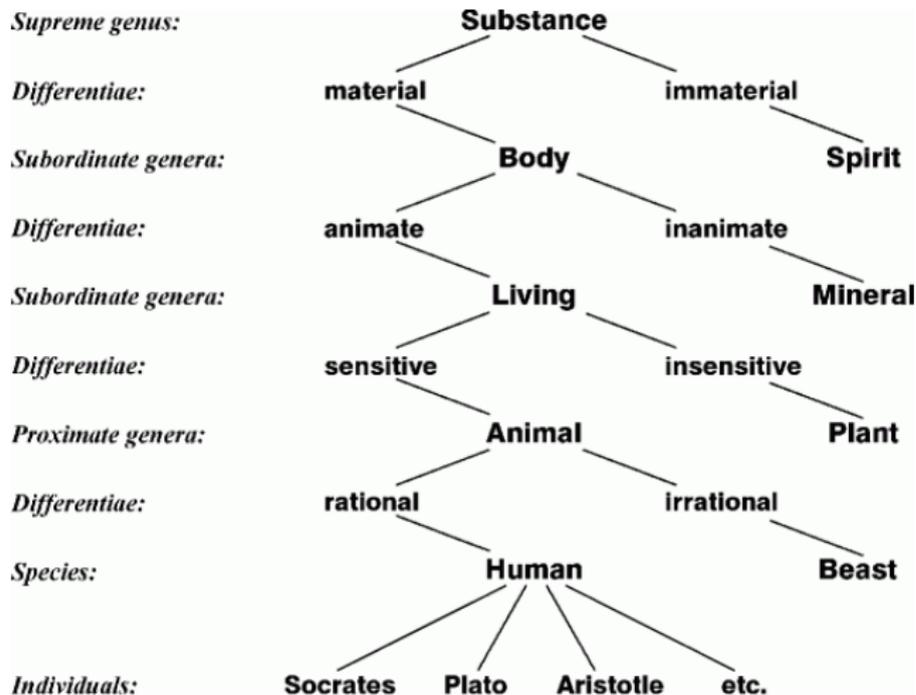
# Sémantické třídy

= skupiny slov, která sdílejí nějakou sémantickou vlastnost

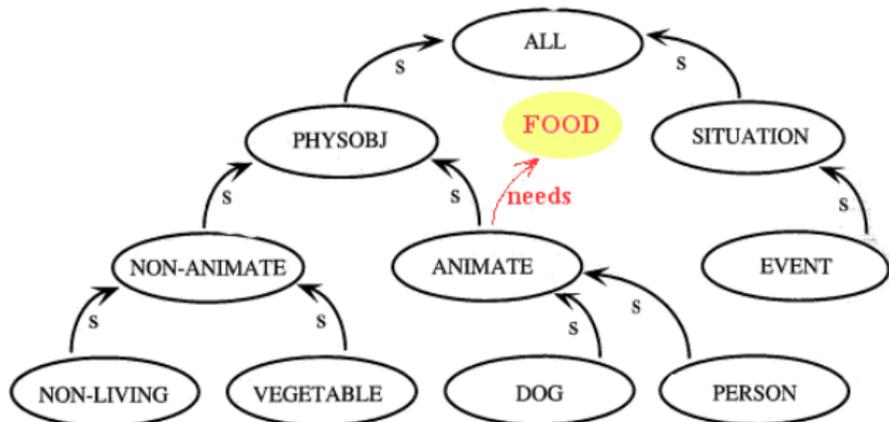
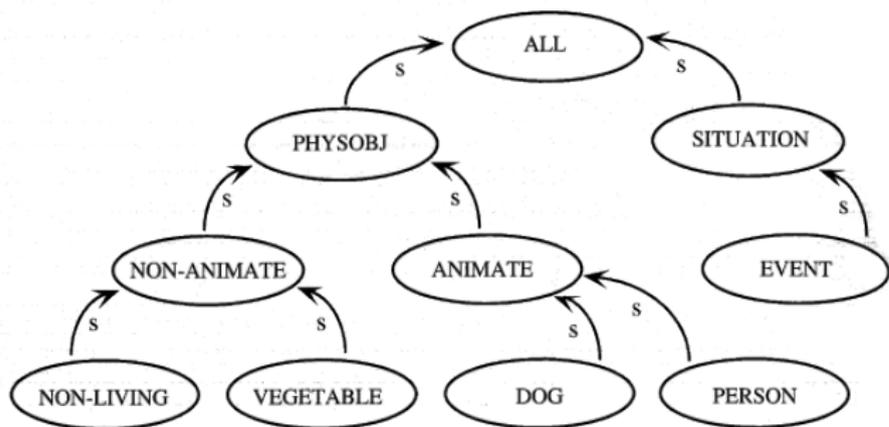
obratlovec – savec – šelma – psovitá šelma – pes – pudl – trpasličí pudl

taxonomie, hierarchie tříd

# Sémantické třídy, Porfyriův strom



# 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
  - ▶ troponymie: šeptat – mluvit
  - ▶ near-antonym: den – noc
  - ▶ odvození: velikost – velký
- slovní druhy: substantiva, adjektiva, verba, adverbia

# WordNet

angličtina: PWN (117 tis. synsetů)

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

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

projekty (BalkaNet), 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

# 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

## PA153 Zpracování přirozeného jazyka

└ Popis lexikálních významů pro ZPJ

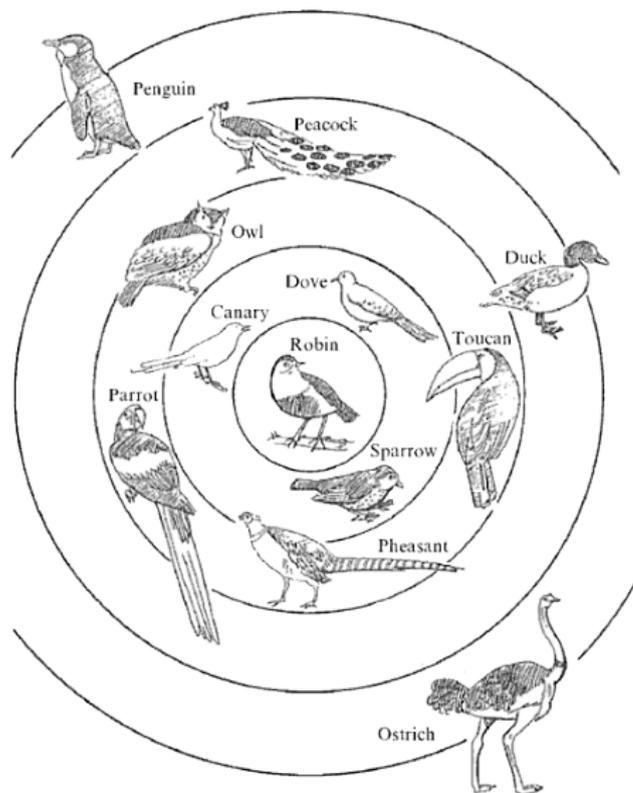
└ Sémantické třídy

└ 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

O jazycích SW příště, v souvislosti s popisem významu věty.

# 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.

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
<b>sémantika</b>	<b>sémantická třída</b>
pragmatiky	

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



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.



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.

## Odkazy II



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 III



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).