

# Významy slov

## Výpočetní sémantika a základní sémantické struktury

Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

Obsah:

- ▶ Významy slov a významové vztahy
- ▶ Slovníky a specializované lexikony
- ▶ Výpočetní sémantika

## Polysemie

Slovo, které má více významů se označuje jako:

- ▶ **polysémní** – významy slova spolu **něčím souvisejí**

... mnozí z nich měli v očích slzy ...  
 ... zase šlápnutí na kuří oko voličů ...  
 ... osmažená vejce na volská oka pokrájená ...  
 ... Technologie Jestřábí oko spolehlivě určí, zda byl míček dobrý...

- ▶ **homonymní** – příš se stejně, ale jejich **významy spolu nesouvisí**

(může být *homografní* nebo *homofonní* – být/být)

... azuro na obloze, zelená travička pod nohami...  
 Jednou z nejslavnějších profesionálních traviček se stala Locusta

... zajišťujeme kompletní zákaznický servis ...  
 ... Broušený servis , skutečný domácí postrach, který se dědí ...  
 ... reklamace zboží v autorizovaném servisu ...  
 ... Hingisová sice hned prohrála servis , ale z 0:1 otočila ...

**Slovo:**

- ▶ **slovní tvar** (*wordform*) – slovo zapsané v textu
- ▶ **lemma/základní tvar** – slovo v indexové/citační podobě (nominativ, singulár, ...) váže se na lexikální význam
- ▶ lemma i slovní tvar může mít víc **významů** (*word sense*):  
 (pozor na rozdíl *význam jako meaning* a *význam jako sense*)
  - ... musel rozhodčí napomínat za vzteklé mlácení raketou ...
  - ... cvičně odpálila balistickou raketu středního doletu, která je ...
  - ... vystoupení v latinsko-amerických tancích na Vašich kulturních akcích ...
  - Při nácviku brodění totiž v tancích navlhly kably a vojáci je ...

## Polysemie

Některé typy **polysemie** jsou **systematické**:

- ▶ budova ↔ organizace ↔ osoby

... Nemocnice byla postavena v listopadu 1873 ...  
 ... Nemocnice údajně dluží členům asociace 1,5 miliardy ...  
 ... Prachatická nemocnice ošetřila také 19 lehce zraněných ...

- ▶ viz **metonymie** – autor ↔ dílo, strom ↔ ovoce

korigovali text Hovorů proto, že tu bylo více Čapka a méně autentického Masaryka.  
 o tom hovořil ve své knize už Karel Čapek ...  
 ... u hrázeck byla tehdy taková silná hruška ...  
 ... tam, kde je na hrušce stopka, ...

**Zeugma test** na polysemii:

- ▶ *Kdo rád stráví silvestrovskou noc při dunění petard?*
- ▶ *Pak se však Mach pokusil strávit příliš velké sousto.*
- ▶ → *Kdo rád stráví silvestrovskou noc a příliš velké sousto při dunění petard?*

# Word Sense Disambiguation

## správné určení významu – **word sense disambiguation**

- ▶ WSD má vliv na:

- vyhledávání informací (určení indexového lemmatu)
- strojový překlad ("bat" → "netopýr" | "pálka")
- výslovnost při řečové syntéze  
(angl. "bass [beɪs]" – bas/basa, "bass [bæs]" – okoun  
čes. "baby [babɪ]" – mn.č. od baba, "baby [beɪbɪ]" – dítě, z angl.)

- ▶ **klasifikační úloha** vztažená k nějakému **katalogu významů** (sense inventory), např. WordNet

úspěšnost záleží na vlastnostech katalogu, např. **granularita**

nejlepší systémy dosahují cca 60 % pro **jemné rozlišení významů** a 80 % pro **hrubé rozlišení** (*fine-grained* × *coarse-grained*)

- ▶ klasifikace určuje **kontexty** odpovídající jednotlivým významům různé metody, od slovníkových po zcela automatické
- ▶ bez katalogu je odpovídající úkol **word sense induction**, určení významů slova podle shluků jeho kontextů

## Synonyma

Dvě slova jsou **synonyma**, když jsou **vzájemně zaměnitelná** v kontextech:

- ▶ notebook ↔ laptop
- ▶ statečný ↔ odvážný
- ▶ chlapec ↔ hoch

většina synonym ale **není zaměnitelná** ve všech kontextech:

- ▶ Samotný prožitek doteku pak má své kouzlo.  
Samotný prožitek doteku pak má svůj půvab.
- ▶ Učení nových útočných i obranných pohybů a kouzel.  
Učení nových útočných i obranných pohybů a půvabů.

**Synonymie** je tedy vazba mezi **významy slov**, ne mezi slovy

# Word Sense Disambiguation – porovnání kontextů

## tank/tanec

czes2 freqs = 10,520   12,826	tank	6.0	4.0	2.0	0	-2.0	-4.0	-6.0	tanec
coord	503	1,538	1.40	3.10					
dělostřelectvo	40	0	9.2	–					
peso	14	0	8.6	–					
transportér	23	0	8.2	–					
houfnice	9	0	8.2	–					
pěchota	32	0	8.1	–					
kanon	6	0	7.1	–					
buldozer	5	0	7.1	–					
samopal	7	0	6.4	–					
kulomet	6	0	6.2	–					
vrtník	22	0	6.2	–					
dělo	26	0	5.8	–					
letadlo	60	0	5.7	–					
muzika	0	15	–	5.4					
rytmus	0	17	–	5.5					
krok	0	5	–	5.5					
zábava	0	35	–	5.8					
aerobik	0	9	–	6.2					
buben	0	12	–	6.4					
balet	0	16	–	6.6					
serm	0	9	–	6.9					
hudba	0	267	–	7.0					
pantomima	0	15	–	7.9					
piseň	0	243	–	8.0					
zpěv	0	177	–	9.2					
poslech	0	147	–	9.8					

## Antonyma

totéž platí pro **antonymii** – slova **opačného významu** nebo **stupně vlastnosti**:

- ▶ tmavý × světlý
- ▶ rychle × pomalu
- ▶ dovnitř × ven

**kontextově** jsou antonyma velice podobná synonymům!

## tmavý/světlý

tmavý	6.0	4.0	2.0	0	-2.0	-4.0	-6.0	světlý
subj_byt	141	106	8.20	7.40				
papír	5	0	15	–				
obrázek	5	0	14	–				
obraz	6	0	14	–				
noc	4	0	13	–				
barva	4	9	0.9	2.1				
modifies	7,316	6,019	5.80	5.60				
býle	205	0	8.8	–				
pečivo	51	0	7.3	–				
mrak	42	4	6.8	3.5				
hnědák	54	7	7.8	5.1				
oblek	153	23	8.6	6.0				
chléb	63	11	7.2	4.8				
plet	504	123	10.0	8.1				
kalhoty	66	19	7.2	5.6				
bunda	39	11	6.7	5.1				
skvma	129	38	8.2	6.6				
pruh	63	28	6.8	5.7				
barva	430	301	7.5	7.1				
vlas	325	226	8.5	8.0				
chloupek	27	28	6.6	6.9				
odstín	150	180	8.3	8.7				
pivo	88	138	6.4	7.1				
dřevo	41	73	5.8	6.7				
lezák	32	68	7.0	8.4				
jíška	17	58	6.2	8.2				
okamžik	0	118	–	6.7				
stezka	0	105	–	7.3				
Karolina	0	54	–	7.8				
výjimka	0	247	–	8.0				
výška	0	343	–	8.1				
zítítek	0	239	–	9.7				

## Hyperonyma a hyponyma

Význam slova  $w_i$  je **hyperonymum (hyponymum)** významu slova  $u_j$ , pokud  $w_i$  je **obecnější (specifický)**:

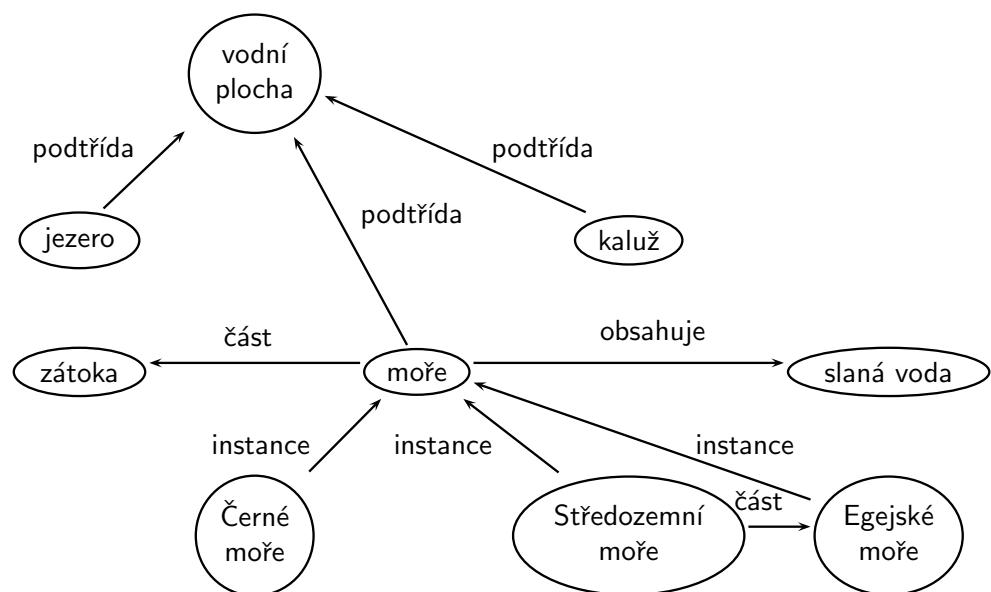
- ▶ kobra je hyponymum slova had
- ▶ stroj je hyperonymum bagr

jiné označení:

- ▶ slova **nadřazená/podřazená** (*superordinate/subordinate*)
- ▶ z logického pohledu  $u_j$  je hyponymum  $w_i \Leftrightarrow$ 
  - **extenzionálně** –  $\text{class}(u_j) \subset \text{class}(w_i)$
  - **vyplývání** –  $\text{property}(x, u_j) \Rightarrow \text{property}(x, w_i)$
- ▶ hypero/hyponymie je obvykle **tranzitivní**  
 $U_j \text{ hyponymum } W_i \wedge W_i \text{ hyponymum } V_k \Rightarrow U_j \text{ hyponymum } V_k$

u sloves podobná relace **tropomorfie** – chodit/pochodovat

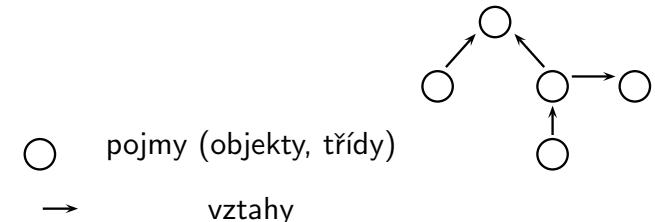
## Sémantické sítě – příklad



## Sémantické sítě

**sémantické sítě** – reprezentace faktových znalostí (pojmy + vztahy)

- ▶ vznikly kolem roku 1960 pro reprezentaci významu anglických slov
- ▶ znalosti jsou uloženy ve formě grafu



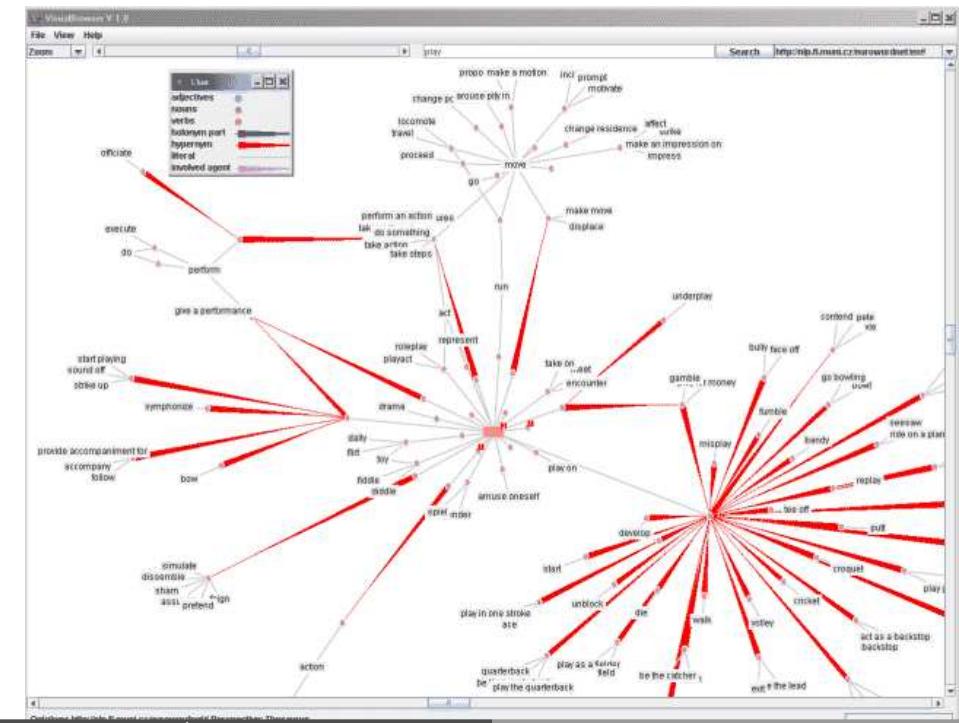
▶ nejdůležitější vztahy:

- **podtřída** (*subclass, is-a*) – vztah mezi třídami
  - **instance** – vztah mezi konkrétním objektem a jeho rodičovskou třídou
- jiné vztahy – část (has-part), barva, ...

## Aplikace sémantických sítí

(Princeton) **WordNet** – <http://wordnet.princeton.edu/>

- ▶ sématická síť 140.000 (anglických) pojmu, zachycuje:
  - synonyma, antonyma
  - hyperonyma, hyponyma
  - odvozenost a další jazykové vztahy
- ▶ jednotka **synset** – synonymická řada  
zachycuje **slabá synonyma** (*near-synonyms*)
- ▶ tvoří se **národní wordnety** (navázané na anglický WN)  
**český wordnet** – cca 30.000 pojmu
- ▶ nástroj na editaci národních wordnetů – **DEBVisDic**, vyvinutý na FI MU
- ▶ VisualBrowser –  
<http://nlp.fi.muni.cz/projekty/visualbrowser/>  
nástroj na vizualizaci (sémantických) sítí, vznikl jako DP na FI MU



## Slovníky a specializované lexikony

**Slovníky** typicky obsahují:

- ▶ specifikace **formy**:
  - grafická podoba – alternativy, dělení, velká počáteční písmena
  - zvuková podoba – výslovnost a její alternativy, slabiky, přízvuk, výška
- ▶ **gramatické** (morfo-syntaktické) **informace** – slovní druh a příslušné gramatické kategorie, morfologický vzor?
- ▶ specifikace **významu** – hierarchie

**slovník** uvádí významy listémů, **encyklopédie** informace o jejich denotátech

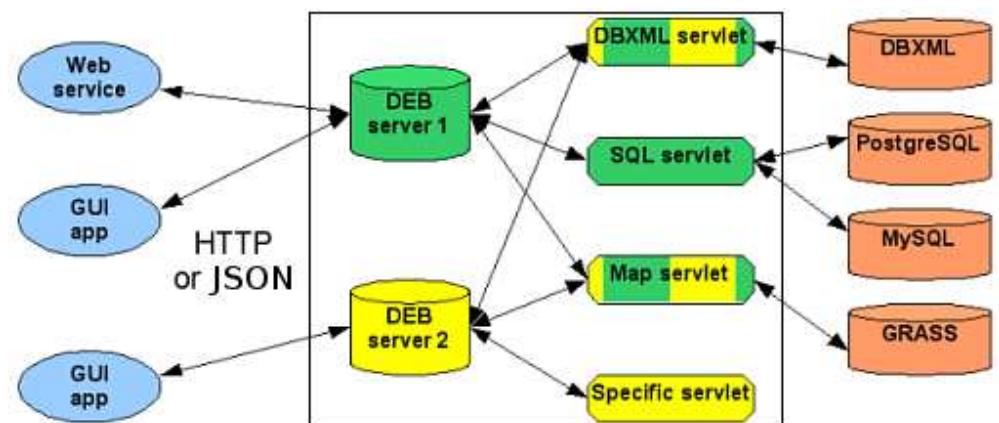
Slovník spisovné češtiny: tetřev, **-a m** velký lesní pták z příbuzenstva kura domácího [x] **tokat jako tetřev**, expr. být slepě zamilován; tetřeví příd. **tetřeví tokání**, **tetřeví slepice**.

Encyklopédie Diderot: tetřev, Tetrao, rod hrabavých ptáků, kteří obývají pásmo jehličnatých lesů severní polokoule. V ČR žije dnes již vzácně tetřev hlušec (Tetrao urogallus). Největší z lesních kurů, kohout dosahuje hmotnosti až 6 kg.

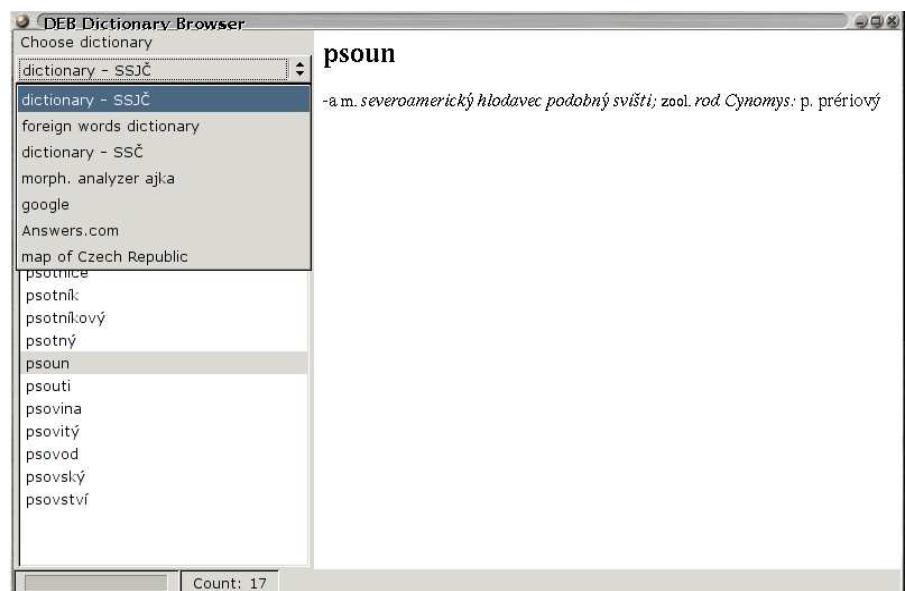
specializované lexikony a encyklopédie (znalost odborníků a rozdílné předpoklady a požadavky)

## DEB – platforma pro vývoj slovníků

- ▶ **Dictionary Editor and Browser, DEB**
- ▶ platforma pro vývoj **systémů na psaní slovníků** (*dictionary writing systems*, DWS)
  - <http://deb.fi.muni.cz/>
  - pracuje s hesly ve formě XML struktury
- ▶ strikní **klient-server architektura**
- ▶ server
  - specializované moduly – *servlety*
  - databázové úložistě
- ▶ klient
  - jen jednoduchá funkcionality
  - GUI i web rozhraní – postavený na *Mozilla Engine*



DEB používá komunikaci typu AJAX



## DEBDict – příklad DEB klienta

- ▶ přehledné **prohledávání slovníků** s různou strukturou
- ▶ původně určený pro demo základních funkcí
- ▶ dostupný jako instalovatelné **rozšíření Firefoxu** i jako vzdálená **webová služba**
- ▶ vícejazyčné uživatelské rozhraní (angličtina, čeština, další lze snadno doplnit)
- ▶ dotazy do několika **XML slovníků s různou strukturou**, výsledky jsou zpracovány XSLT transformací
- ▶ **autentizace** – uživatelé mají různá práva přístupu ke slovníkům
- ▶ napojení na **externí služby**:
  - český morfologický analyzátor
  - externí webové služby (Google, Answers.com, Wikipedia)
  - geografický informační systém – zobrazení geografických odkazů přímo na mapě

## DEB – platforma pro vývoj slovníků

- ▶ další aplikace:
  - **DEBVisDic** – editor wordnetů
  - **Cornetto** – editor lexikální databáze (University of Amsterdam)
  - **TeDi** – terminologický slovník
  - **FaNUK** – slovník anglických příjmení (University of West England, Oxford University Press)
  - ...
- ▶ použitá v **22 mezinárodních projektech**
- ▶ DEB server v Brně využívá více než **1300 registrovaných uživatelů**





# Problémy sémantiky s jazykovými zdroji

## Problémy jazykových zdrojů:

- ▶ nejsou dostupné pro každý **jazyk**
- ▶ neobsahují všechna **slova**
- ▶ neobsahují dost kombinací slov, **frází**
- ▶ neobsahují všechny **významy**
- ▶ neobsahují všechny **relace**
- ▶ naopak obsahují i (velmi) **málo frekventované** významy/relace (jak – spojka/zvíře, s – předložka/citoslovce, tři – číslovka/sloveso)
- ▶ relace nejsou stejně strukturované pro **různé slovní druhy** (H/H  
relace moc nefunguje pro přídavná jména, slovesa)

## Podobnost dokumentů a slov

### Podobnost dokumentů:

- ▶ důležitá např. pro **vyhledávání informací**
- ▶ dokument (dotaz) = **vektor frekvencí (TF-IDF frekvenčních skóre) slov**

doc1: Hotel byl krásný, ale personál hotelu nepříjemný.

doc2: Hotel je standardní a jídlo v hotelu vynikající.

query: hotel a jídlo

	doc1	doc2	query
a	0	1	1
ale	1	0	0
byl/být	1	2	0
hotel	2	2	1
hotelu/hotel	1	1	0
je/být	0	1	0
jídlo	0	1	1
krásný	1	0	0
nepříjemný	1	0	0
personál	1	0	0
standardní	0	1	0
✓	0	1	0
vynikající	0	1	0

$$\text{vec}_{\text{doc1}} = \langle 1, 2, 0, 1, 1, 1, 0, 0 \rangle$$

$$\text{vec}_{\text{doc2}} = \langle 2, 2, 1, 0, 0, 0, 1, 1 \rangle$$

$$\text{vec}_{\text{query}} = \underbrace{\langle 0, 1, 1, 0, 0, 0, 0, 0 \rangle}_8$$

### snížení (prokletí) dimensionality:

- ▶ **výběr rysů (feature selection)** – stop slova, frekventovaná slova, ...
- ▶ **extrakce rysů (feature extraction)** – lemmatizace/stemming, latentní sémantická analýza, ...

## Distribuční sémantické modely

alternativa – automatické **distribuční sémantické modely**

- ▶ také **vektorové modely (vector-space models)**
- ▶ slova/fráze/dokumenty nahrazujeme **body v N-rozměrném vektorovém prostoru (vektory)** (kde  $N$  může být velké číslo – stovky tisíc)
- ▶ modely se počítají automaticky z rozsáhlých textových sad
- ▶ dosahují **vyšší pokrytí**, ale **menší přesnost** než "ruční" jazykové zdroje
- ▶ primární počítaná **sémantická operace – podobnost**

## Podobnost dokumentů

2 dokumenty jsou **podobné**  $\Leftrightarrow$  jsou podobné jejich **vektory**

	doc1	doc2	query
být	1	2	0
hotel	2	2	1
jídlo	0	1	1
krásný	1	0	0
nepříjemný	1	0	0
personál	1	0	0
standardní	0	1	0
vynikající	0	1	0

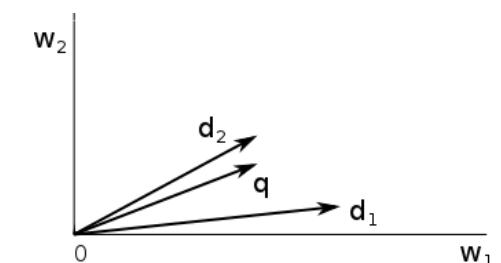
doc1: Hotel byl krásný, ale personál hotelu nepříjemný.  
doc2: Hotel je standardní a jídlo v hotelu vynikající.  
query: hotel a jídlo

podobnost vektorů se určuje **cosinovou podobností**

(normalizovaný skalární součin vektorů)

$$\text{sim}_{\text{cos}}(\text{doc}_1, \text{query}) = 0.5$$

$$\text{sim}_{\text{cos}}(\text{doc}_2, \text{query}) = 0.64$$



# Podobnost slov

analogicky **slovo = vektor frekvencí slova v dokumentech**

	doc1	doc2	query
být	1	2	0
hotel	2	1	1
jídlo	0	1	1
krásný	1	0	0
nepříjemný	1	0	0
personál	1	0	0
<b>standardní</b>	<b>0</b>	<b>1</b>	<b>0</b>
<b>vynikající</b>	<b>0</b>	<b>1</b>	<b>0</b>

$$\begin{aligned} \text{vec}_{\text{standardní}} &= \langle 0, 1, 0 \rangle \\ \text{vec}_{\text{vynikající}} &= \langle 0, 1, 0 \rangle \end{aligned}$$

2 slova jsou **podobná**  $\Leftrightarrow$  jsou **podobné** jejich vektory

(to samozřejmě funguje lépe na velkých datech)

# Reprezentace slov

reálně se místo dokumentů používají **kontexty**

... jsou na látky obsažené v čokoládě (kofein, theobromin) mimořádně citliví a nedokáží je ...  
 ... kofein, který najdete v čokoládě, a theobromin působí stimulačně na centrální nervový ...  
 ... se skrývá mimo jiné fenyletylamin a theobromin, přičemž mu jsou přisuzovány opojné ...  
 ... podoba v čaji se nazývá theofylin a v kakau theobromin – účinky jsou prakticky stejné ...  
 ... celospolečensky tolerované drogy, jako kofein, theobromin, nebo nikotin ...

z kontextů poznáme (odhadneme, kontexty určují) **význam slova**

(theobromin – látka vyskytující se v čokoládě s podobným stimulačním účinkem jako kofein)

# Reprezentace slov

místo frekvencí slov –

**skóre vzájemné informace (Mutual Information (MI) score)**

MI skóre pro **pravděpodobnostní jevy** – vyskytuje se jevy  $X$  a  $Y$  spolu více, než kdyby byly nezávislé?

$$MI(X, Y) = \log_2 \frac{P(X, Y)}{P(X)P(Y)}$$

MI skóre pro **slova/kontexty** – vyskytuje se slovo *word* v kontextu *context* více, než kdyby byly nezávislé?

$$MI(\text{word}, \text{context}) = \log_2 \frac{P(\text{word}, \text{context})}{P(\text{word})P(\text{context})}$$

může se upravovat **vážením (weighting)** a **vyhlazováním (smoothing)**

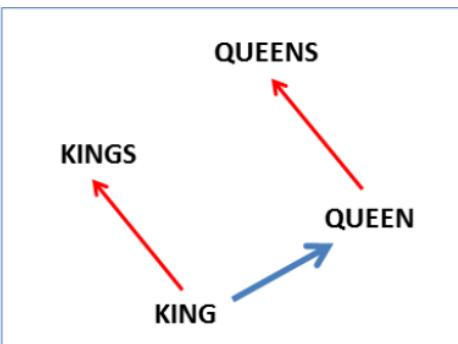
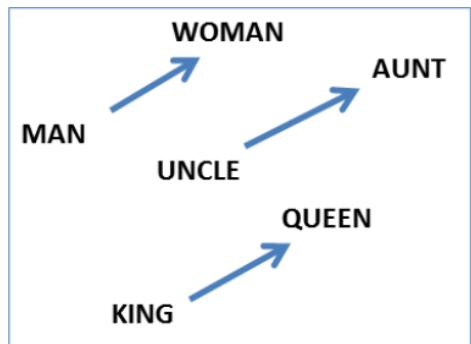
- ▶ jiný způsob **reprezentace významu slov** ve **vektorovém prostoru**
- ▶ na principu **extrakce rysů** – počet rysů stanovíme (třeba 1000)
- ▶ slovo inicializujeme jako **náhodný vektor** v prostoru rysů
- ▶ cyklicky upravujeme vektory tak, abychom maximalizovali **podmíněnou pravděpodobnost** mezi **slovem** a jeho **kontexty**

$$\arg \max_{\theta} \prod_{(w,c) \in D} P(c|w; \theta)$$

- ▶ algoritmy – **word2vec** (Mikolov, Google, princip učení neuronové sítě), **GloVe** (Pennington et al, Stanford Uni, faktorizace matic) pro kvalitní výstupy je potřeba **velmi velká data** (miliardy slov) existují rozšíření na fráze (**phrase2vec**) a dokumenty (**doc2vec**)

## Zapouzdření slov (Word Embedding)

**sémantické vlastnosti** výsledných vektorů



(příklady od T.Mikolova)

## Zapouzdření slov (Word Embedding)

**sémantické vlastnosti** výsledných vektorů

operace s vektry	nejbližší výsledný vektor
Paris - France + Italy	Rome
bigger - big + cold	colder
sushi - Japan + Germany	bratwurst
Cu - copper + gold	Au
Windows - Microsoft + Google	Android
Montreal Canadiens - Montreal + Toronto	Toronto Maple Leafs

(příklady od T.Mikolova)

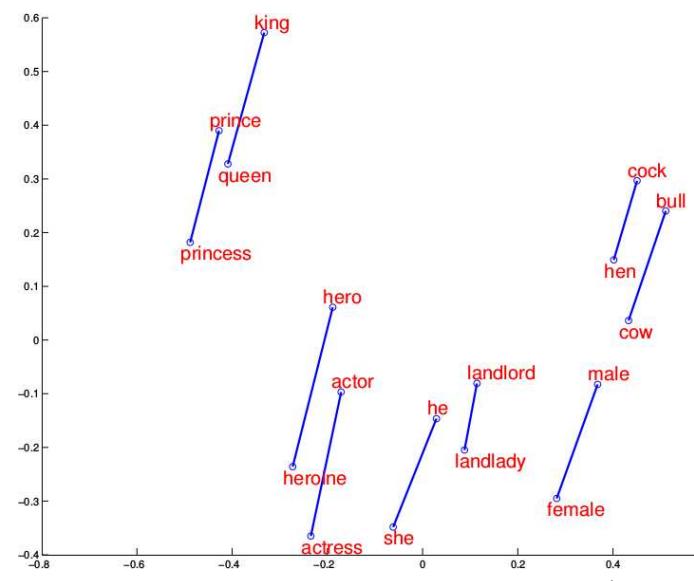
## Zapouzdření slov (Word Embedding)

**sémantické vlastnosti** výsledných vektorů

operace s vektry	nejbližší vektor
Czech + currency	koruna, Czech crown, Polish zloty, CTK
Vietnam + capital	Hanoi, Ho Chi Minh City, Viet Nam, Vietnamese
German + airlines	airline Lufthansa, carrier Lufthansa
Russian + river	Moscow, Volga River, upriver, Russia
French + actress	Juliette Binoche, Vanessa Paradis

(příklady od T.Mikolova)

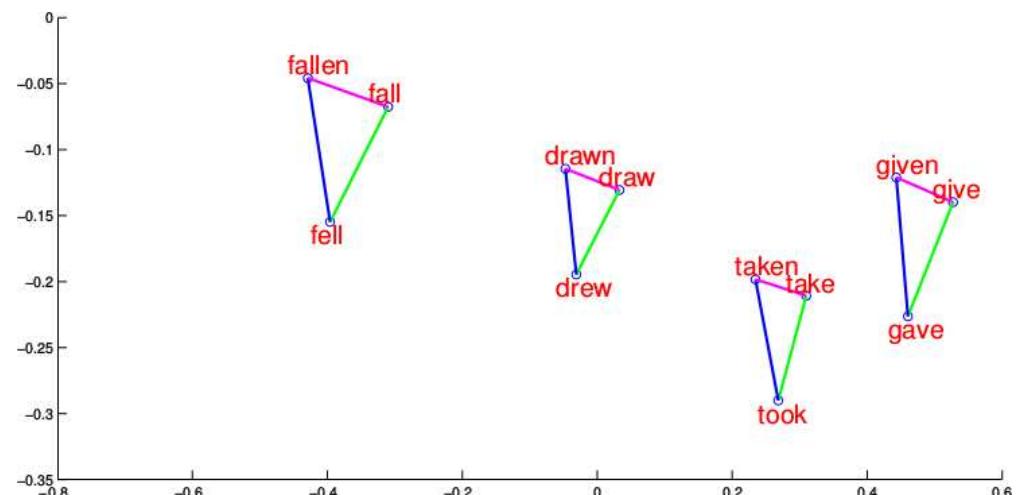
## Zapouzdření slov (Word Embedding) vizualizace pravidelností výsledných vektorů



(příklady od T.Mikolova)

## Zapouzdření slov (Word Embedding)

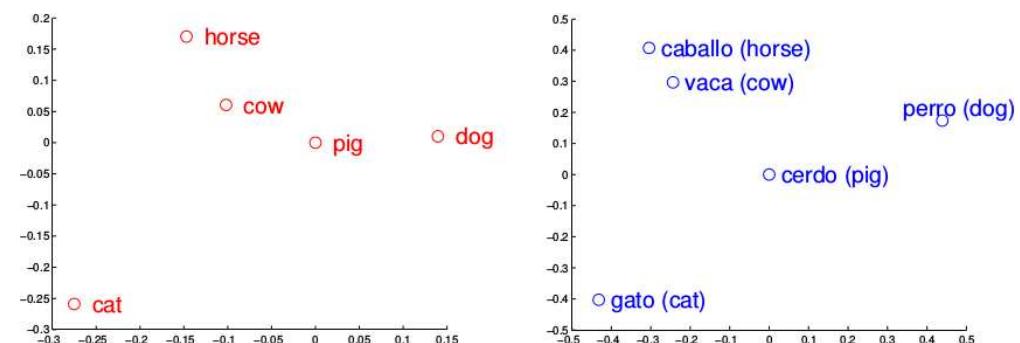
### vizualizace pravidelností výsledných vektorů



(příklady od T.Mikolova)

## Zapouzdření slov (Word Embedding)

využití vektorových reprezentací pro **strojový překlad**  
prostory různých jazyků je nutné **lineárně transformovat** (otočit, zmenšit)



(příklady od T.Mikolova)