

# Výpočetní sémantika a základní sémantické struktury

Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)

[http://nlp.fi.muni.cz/nlp\\_intro/](http://nlp.fi.muni.cz/nlp_intro/)

Obsah:

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

# Významy slov, polysemie

## 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 kabely a vojáci je ...

## Významy slov, polysemie

Slovo, které má více významů se označuje jako:

► **polysémní** – významy slova spolu **něčím souvisí**

- ... 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** – píší se stejně, ale jejich **významy spolu nesouvisí**  
(může být *homografní* nebo *homofonní* – **bít/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 ...

# Významy slov, 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 [beis]" – bas/basa, "bass [bæs]" – okoun  
čes. "baby [babij]" – mn.č. od baba, "baby [beibi]" – 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

# 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	post_verb	342	498	1.20	1.30	a_modifier	3,218	5,764	1.70	2.20
dělostřelectvo	40	0	9.2	--	útočit	6	0	4.2	--	modernizovaný	65	0	9.0	--
peso	14	0	8.6	--	vyrábět	5	0	1.9	--	sovětsky	318	0	8.4	--
transportér	23	0	8.2	--	potrebovat	6	0	0.8	--	vyprošťovací	29	0	8.0	--
houfnice	9	0	8.2	--	začít	0	0	--	0.2	zničený	38	0	7.4	--
pěchota	32	0	8.1	--	patřit	0	18	--	1.3	zastarálý	24	0	6.9	--
kanon	6	0	7.1	--	věnovat	0	7	--	1.3	mostní	15	0	6.9	--
buldozer	5	0	7.1	--	hrát	0	18	--	1.3	Wittmannův	11	0	6.8	--
samopal	7	0	6.4	--	pokračovat	0	8	--	1.3	lehký	103	5	6.9	2.4
kulomet	6	0	6.2	--	představit	0	8	--	1.6	moderní	40	238	4.5	7.0
vrtulník	22	0	6.2	--	začínat	0	12	--	2.0	latinskoamerický	8	90	5.8	8.7
dělo	26	0	5.8	--	pomáhat	0	6	--	2.1	povinný	7	91	3.3	6.9
letadlo	60	0	5.7	--	vycházet	0	9	--	2.1	originální	0	69	--	6.8
muzika	0	15	--	5.4	bavit	0	6	--	3.2	společenský	0	144	--	6.8
rytmus	0	17	--	5.5	předvést	0	7	--	3.3	lidový	0	157	--	7.0
krok	0	5	--	5.5	zahrát	0	19	--	4.5	dvojlákův	0	38	--	7.2
zábava	0	35	--	5.8						írský	0	69	--	7.3
aerobik	0	9	--	6.2						country	0	77	--	7.8
buben	0	12	--	6.4						výrazový	0	50	--	7.8
balet	0	16	--	6.6						scénicky	0	63	--	8.0
šerm	0	9	--	6.9						dobový	0	104	--	8.1
hudba	0	267	--	7.0						rituální	0	62	--	8.2
pantomima	0	15	--	7.9						slovanský	0	104	--	8.2
písceň	0	243	--	8.0						hrisny	0	92	--	8.7
zpěv	0	177	--	9.2						brnění	0	329	--	10.3
poslech	0	147	--	9.8						orientální	0	404	--	10.6

# 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

# 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

czes2 freqs = 8,960 | 8,127

tmavy	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	1.5	–				
obrázek	5	0	1.4	–				
obraz	6	0	1.4	–				
noc	4	0	1.3	–				
barva	4	9	0.9	2.1				
modifies	7,316	6,019	5.60	5.60				
brylé	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				
plét	504	123	10.0	8.1				
kalhoty	66	19	7.2	5.6				
bunda	39	11	6.7	5.1				
skvrna	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				
ležák	32	68	7.0	8.4				
jiška	17	58	6.2	8.2				
okamžik	0	118	–	6.7				
stezka	0	105	–	7.3				
Karolina	0	54	–	7.8				
vyjímka	0	247	–	8.0				
výška	0	343	–	8.1				
zítřek	0	239	–	9.7				

# Hyperonyma a hyponyma

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

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

jiné označení:

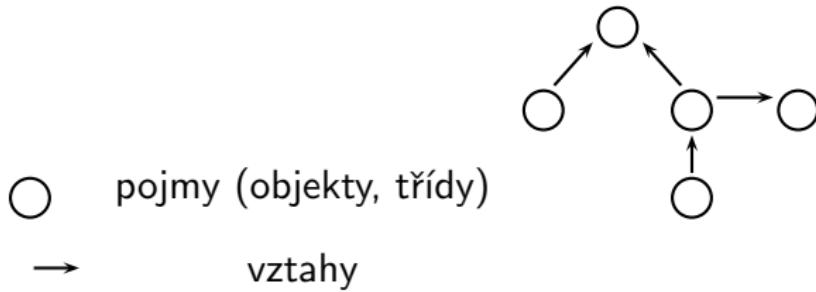
- ▶ slova **nadřazená/podřazená** (*superordinate/subordinate*)
- ▶ z logického pohledu  $u_j$  je hyponymum  $w_i \Leftrightarrow$ 
  - **extenzionálně** –  $\text{class}(u_j) \subset \text{class}(w_i)$
  - **vyplývání** –  $\text{property}(x, u_j) \Rightarrow \text{property}(x, w_i)$
- ▶ hypero/hyponymie 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 **troponymie** – **chodit/pochodovat**

# 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, ...


## Sémantické sítě – příklad



# 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



**DEBVisDic**

- User Settings Tools Windows Help

**Dictionary - SSJČ**

dog: dictionary - SSČ  
Morph. analyzer ajka Google

[n] andiron:1, firedog:1, dog:7, dog:  
[n] frump:1, dog:2  
[n] cad:1, bounder:1, blackguard:1, dog:4, houn:  
[n] dog:1, domestic dog:1, Canis familiaris:1  
[n] frank:2

**English Wordnet**

Search

**Greek Wordnet**

.οδ ικό Search

[n] περιστοικό:1  
[n] περιστοικό:0

**Russian Wordnet**

Search

[n] журнál

**Czech Wordnet**

Search

Preview Tree RevTree

pes

POS: n  
Synonyms:  
Definition:  
wolf) that  
many bre  
Usage: t  
Domain:  
SUMO/N  
-> [hyp

[n] zakopaný pes:1  
[n] policejní pes:1  
[n] hlídací:4, hlídací pes:1  
[n] pes:1  
[n] slepecký pes:1, vodící pes:1

Preview Tree RevTree Edit XML

-<SYNONYM>  
  <LITERAL>Inote="" sense="1">pes</LITERAL>  
  <WORD>pes</WORD>  
</SYNONYM>

<ILR type="hypernym">ENG20-020005  
<ILR type="holo\_member">ENG20-020  
<ILR type="holo\_member">ENG20-075  
<STAMP>xapek1 2003/06/25</STAMP>  
<BCS>3</BCS>  
<RILR type="hypernym">ENG20-02002  
<RILR type="hypernym">ENG20-02027

Number of entries: 12

number of entries: 3

**Show in Czech Wordnet**

Definit  
сброш  
Usage  
били  
Usage  
театр?  
-> [has\_hypernym] печатное издание:1

Take key from Czech Wordnet  
AutoLookUp in  
Copy entry to Czech Wordnet  
Import IDs from file

Number of entries: 1

# 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, **encyklopedie** 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*.

Encyklopedie 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 encyklopedie (znalost odborníků a rozdílné předpoklady a pohledy)

# 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
- ▶ striktní *klient-server architektura*
- ▶ server
  - specializované moduly – *servlety*
  - databázové úložistě
- ▶ klient
  - jen jednoduchá funkcionalita
  - 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 Dictionary Browser

Choose dictionary

- dictionary - SSJČ
- dictionary - SSJČ**
- foreign words dictionary
- dictionary - SSČ
- morph. analyzer ajka
- google
- Answers.com
- map of Czech Republic

psotnice

psotník

psotníkový

psotný

**psoun**

psouti

psovina

psovity

psovod

psovský

psovství

Count: 17

**psoun**

-a m. severoamerický hlodavec podobný svišti; zool. rod *Cynomys*; p. prériový

# 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 [1600 registrovaných](#) uživatelů



# České valenční lexikony

specializované lexikony slovesných valencí:

- ▶ syntaktické valenční rámce [Brief](#) (FI MU, od 1997) cca 15,000 sloves:  
lámat <v>hPTc4,hPTc4-hTc7,hPc3-hTc4
- ▶ valenční rámce v [českém wordnetu](#) (FI MU 2000), cca 3,000  
slovesných literálů (sloveso+význam):  
synset: lámat:3, dobývat:1, těžit:2  
valence: kdo1\*AG(person:1)=co4\*SUBS(substance:1)  
valence: co1\*AG(institution:1)=co4\*SUBS(substance:1)
- ▶ pražský lexikon [Vallex 1.0](#), na začátku roku 2005 cca 1,000 sloves  
(ted' snad až 4,000):  
~ impf: lámat  
+ ACT(1;obl) PAT(4;obl)

# Valeční lexikon VerbaLex

- ▶ vznikl na začátku roku 2005, využívá všech [dostupných zdrojů](#)
- ▶ edituje se ve formulářovém editoru nebo v jednoduchém textovém formátu, který se pro další zpracování převádí do [XML](#)
- ▶ vlastnosti:
  - dvouúrovňové [sémantické role](#)
  - odkazy na hypero/hyponymickou [hierarchii](#) v českém [wordnetu](#)
  - odlišení [životnosti](#) a neživotnosti větných členů
  - implicitní pozice [slovesa](#)
  - valenční rámce se odkazují na číslované [významy sloves](#)
- ▶ exporty z XML do HTML pro prohlížení a PDF pro tisk

## VerbaLex v HTML

# Využití valencí v sémantické analýze

reprezentace **slovesného rámce**:

1. syntaktické rysy:

- dávat něco<sub>neživ.NP</sub>, 4.pád, bez předložky
- někomu<sub>živ.NP</sub>, 3.pád, bez předložky

2. sémantické rysy:

dávat Patiens Addressee

3. funkce významu:

**dávat**  $x \dots (o(o\pi)(o\pi))_\omega$ , slovesný objekt

**dávat**/ $(o(o\pi)(o\pi))_{\omega\mu} \quad x \dots \iota \quad y \dots \iota : s_{wty}, s \dots (o\iota)_{\tau\omega}$

**překlad** z valenčního výrazu do funkce významu:

- |                     |  |
|---------------------|--|
| typ argumentu = typ | <ul style="list-style-type: none"> <li>▶ jmenné skupiny</li> <li>▶ příslovečné fráze</li> <li>▶ vedlejší věty</li> <li>▶ infinitivu</li> </ul> |
|---------------------|--|

# 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)

# 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 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
v	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, ...

# Podobnost dokumentů

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

podobnost vektorů se určuje cosinovou podobností:


$$\frac{\vec{a} \cdot \vec{b}}{||\vec{a}|| \cdot ||\vec{b}||}$$

	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

(normalizovaný skalární součin vektorů,  
cosinus úhlu mezi vektory)

$$sim_{cos}(doc_1, query) = 0.5$$

$$sim_{cos}(doc_2, query) = 0.64$$



doc1: Hotel byl krásný, ale personál hotelu nepříjemný.

doc2: Hotel je standardní a jídlo v hotelu vynikající.

query: hotel a jídlo

# 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
standardní	0	1	0
vynikající	0	1	0

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

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

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 theofyllin 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*)

## Zapouzdření slov (Word Embedding)



- ▶ 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 vektory	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)

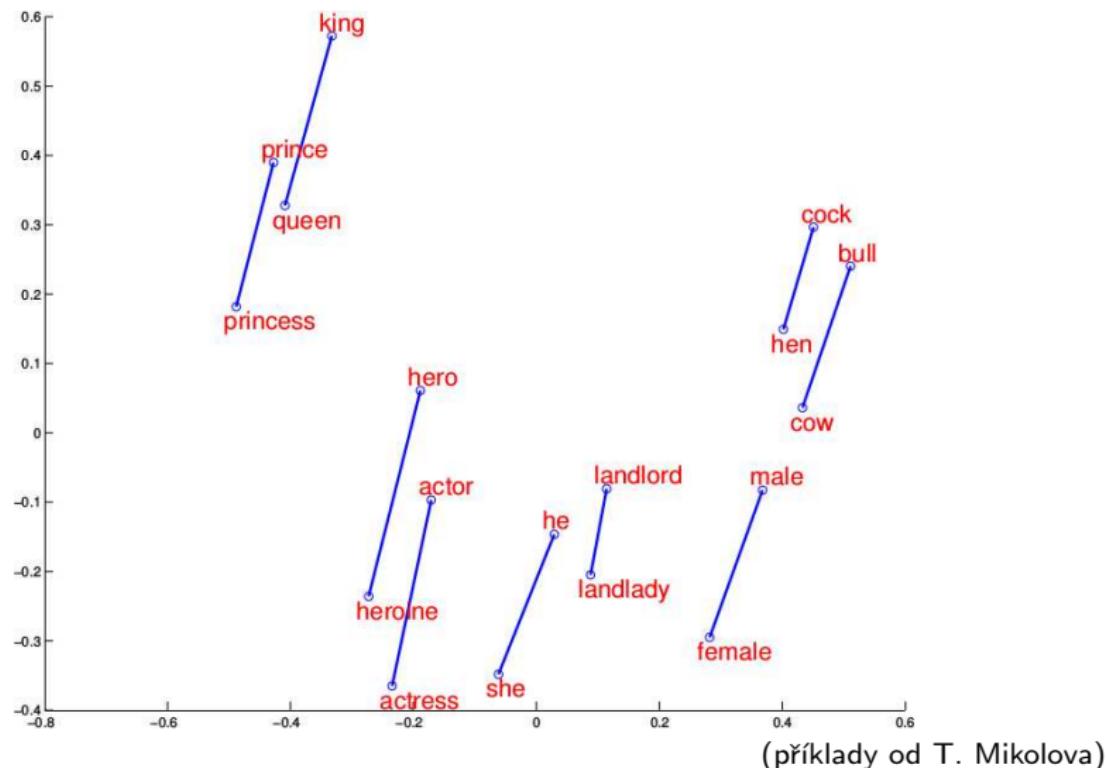
sémantické vlastnosti výsledných vektorů

operace s vektory	nejbližší vektory
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)