



---

# PLIN021 SÉMANTICKÁ ANALÝZA V PRAXI

ZUZANA NEVĚŘILOVÁ  
2020/21

# LEXIKÁLNÍ DESAMBIGUACE

## OPAKOVÁNÍ

- Lexikální desambiguace je přirazení slova v daném kontextu významu v určitém repozitáři významů (např. Slovníku).
- Leskův algoritmus řeší úlohu porovnáním kontextu slova se slovy z definice významu.
- V definici nutně nemusejí být slova, která se vůbec kdy s hledaným slovem vyskytují.
- Úspěch algoritmu silně závisí na použitém slovníku.
- Slovníky nebyly napsány s cílem být zdrojem pro algoritmus WSD.
- Je tedy třeba se porozhlédnout po **jiných algoritmech**.

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

hledáme význam *s* slova *w*

1. vezmi všechny výskyty slova *w* z korpusu včetně jejich kontextů
2. pro každý možný význam slova, vytvoř malou sadu příkladů (buď ručně, nebo pomocí kolokací)
3. vytvoř rozhodovací seznam s pravděpodobnostmi pro další slova, která se vyskytují v kontextech a aplikuj tento seznam na celý korpus (s prahem pro pravděpodobnost)
4. nově zařazená slova obsahují další slova v kontextech
5. algoritmus můžeme upravit pomocí zařazení předpokladu *one-sense-per-discourse*
6. opakuj kroky 3–6
7. Jakmile množiny označených výskytů přestanou narůstat, zastav
8. systém je nyní natrénovaný i na jiný korpus!

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

## 1 vezmi všechny výskyty slova w z korpusu včetně jejich kontextů

místo – mítan benzínovou pumpu, jste ty **kočky** neprémístili jinam. "Nevíte, kde jsou ty nepřemístili jinam. "Nevíte, kde jsou ty **kočky**, co měly být na výstavišti?" "Kočky? Zeptejte ty kočky, co měly být na výstavišti?" " **Kočky**? Zeptejte se kolegyně, já nedávno nastoupila ale nevím. U nás žádný plakát nevisel." " **Kočky** se nevedou!" povzdechla jsem a zavrtěla zaslechl a přidal se k hovoru. "Chcete vidět **kočky**?" "Jste místní? Ano, chceme! Tam nahoře plešatých, mouratých, černých, bílých a jiných **koček**. "Chudinky, trápí je," ozvala jsem se. se suďte! A ostatní se přidávali, brali **kočky** pro sebe i pro sousedy, pro známé a příbuzné No a pan z posledního auta si vzal místo **kočky** překvapenou Jarunu a odvezl ji k sobě do " Jindy se s ní zkouším domluvit: "Hele, **Kočko**, dneska by se mi vážně hodilo, abys zůstala aby to dneska všechno dobře dopadlo..." **Kočka** je Osobnost a kaše na můj osud. Trénuje Postupem času zjišťuji, že jsem se naučila brát **Kočku** jako zvířecího kamaráda, který nemá s mým tlapkách moji budoucnost ani věci příští. **Kočka** je zkrátka Kočka. Ulevilo se mi tímto zjištěním budoucnost ani věci příští. Kočka je zkrátkou **Kočka**. Ulevilo se mi tímto zjištěním. Cítím se V některých domácnostech spolu kamarádí **kočka** a pes. V jiných zase spolu žijí masochistka volný čas, energii a peníze na záchrany psů, **koček** a dalších zvířat. Proto tak obdivuji a

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

2. pro každý možný **význam** slova, vytvoř malou sadu příkladů (buď ručně, nebo pomocí kolokací)

Jenže - pokud si lidé budou hady plést s vychytralou mouchou, která narazila na sklo.	<b>Kočka vrtela vousama. pes</b>	, může docházet k úrazům a na to je třeba
byli uvěznění osadníci nuceni jít koně, chov.	<b>kočky, psy</b>	byl mrtvej že žrása okupoval stránky pro
</p><p> Kočička do krabice </p><p> Znáte kočky? Kočka není pes		a dokonce i krysy, které nechtěně přivezli
<p> Kočička do krabice </p><p> Znáte kočky?	<b>Kočka není pes</b>	, mazlí se jen, když sama chce, v opačném
kotátkem bude jen pár měsíců. Snese se s onemocnění, jako je chřipka či nevolnost. Ovšem u 2005) </p><p> Možná jste si jako majitelé Pop Artové prvky a Warhol začal malovat	<b>kočkou váš pes</b>	, mazlí se jen, když sama chce, v opačném
jsem někoho v baráku vzbudil. Vlastně jo - dentifikačního mikročipu používán již delší dobu na pokračují snahy o vyhubení potkanů, zdivočelých stádo uzavírá. Při nebezpečí (cizí člověk, Smrtelná dávka pro krysu je asi 0,02 g, pro V některých domácnostech spolu kamarádí	<b>koček, psů</b>	? Víte, co kočka potřebuje? Než si kotě
	<b>koček a psů</b>	, kuřat či prasat coronaviry způsobují vážná
	<b>kočky, psy</b>	někdy uvědomili rozdíl mezi těmito domácími
	<b>kočky, pes</b>	a prasata, jež byly oblíbeným Wyethovým
	<b>kočkách, psech</b>	Alfík i bejček Kryštof už čekají v pozoru
	<b>koček, psů</b>	a koník: na Novém Zélandu již navíc na
	<b>kočka, pes</b>	, prasat a koz na ostrovech. </p><p> Kde je ), Slasy "sykají" a podupávají předními
	<b>kočky a psy</b>	je smrtelná dávka asi 25krát vyšší. </p>
	<b>kočka a pes</b>	. V jiných zase spolu žijí masochistka se

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

2. pro každý možný **význam** slova, vytvoř malou sadu příkladů (buď ručně, nebo pomocí kolokací)

hned zaujala, byla to typická prvotřídní okouzlí nejen španělská korida, ale i lokální ) </p><p> 24.01.2008 pollypocket11: Bálová ????? </p><p> 02.01.2008 Murtagh1: PLESOVÁ	kočka, blond vlasy kočka s havraními vlasy kočka:zrzavý vlasy kočky.vlasy kočky strkají do vlasů kočka (dlouhé černé vlasy	, pevná větší prsa natěsnané v přiléhavém , jiskrou v těle a jménem Adela v rodném , hnědý oči, žlutý stín, úplně poslední rtěnku , zelené oči, modré stíny, černé šaty, ty jsme vyzkoušeli a lezou na půdu dál. koupili nějaké drátky. Ihned jsem chtěl vědět jak , štíhlá postava, prsa č. 3, vypasované
---	---	--

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

3. vytvoř rozhodovací seznam s pravděpodobnostmi pro další slova, která se vyskytují v kontextech a aplikuj tento seznam na celý korpus (s prahem pro pravděpodobnost)

```
if ('pes' in context(w)) then s(w,A)=1  
if ('vlasy' in context(w)) then s(w,B)=1  
if ('prase' in context(w)) then s(w,A)=0.9  
if ('prsa' in context(w)) then s(w,B)=1  
if ('oči' in context(w)) then s(w,B)=0.6  
if ('člověk' in context(w)) then s(w,A)=0.8
```

---

## LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

4. nově zařazená slova obsahují **další slova** v kontextech

pes → majitel, žrát  
vlasy → pohledná

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

hledáme význam *s* slova *w*

1. vezmi všechny výskyty slova *w* z korpusu včetně jejich kontextů
2. pro každý možný význam slova, vytvoř malou sadu příkladů (buď ručně, nebo pomocí kolokací)
3. vytvoř rozhodovací seznam s pravděpodobnostmi pro další slova, která se vyskytují v kontextech a aplikuj tento seznam na celý korpus (s prahem pro pravděpodobnost)
4. nově zařazená slova obsahují další slova v kontextech
5. algoritmus můžeme upravit pomocí zařazení předpokladu *one-sense-per-discourse*
6. opakuj kroky 3–6
7. Jakmile množny přestanou narůstat, zastav
8. systém je nyní natrénovaný i na jiný korpus!

## LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

? ? ? ? ? ? ? A A A A A A A A  
? ? ? ? ? ? A A A A A A A A  
? ? ? ? ? ? ? A A A A A A A A  
? ? ? ? ? ? ? ? A A A A A A  
B B ? ? ? ? ? ? ? A A  
B B vlas vlas B B ? B ? ? ? ? ? ? ? ?  
? ? B ? ? ? ? ? ? ? ? ?

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

A grid of letters arranged in rows and columns. The letters are black, except for the word 'pes' which is written in red. The grid contains the following letters:  
Row 1: ?, ?, ?, ?, ?, ?, A, A, A, A, A, A  
Row 2: ?, ?, ?, ?, ?, ?, A, A, A, A, A, A  
Row 3: ?, ?, ?, ?, ?, ?, A, ?, A, A, A, A  
Row 4: ?, ?, ?, ?, ?, ?, A, ?, A, A, A, A  
Row 5: ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?  
Row 6: B, B, ?, B, B, B, B, B, B, B, B, B  
Row 7: ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?  
Row 8: ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?  
Row 9: ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?  
Row 10: ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?

# LEXIKÁLNÍ DESAMBIGUACE (YAROWSKI, 1995)

Jakmile množiny  
zařazených slov přestanou  
narůstat, zastav.



# ONE SENSE PER DISCOURSE

- ... if a polysemous word such as *sentence* appears two or more times in a well-written discourse, it is extremely likely that they will all share the same sense.

## LITERATURA

- Wikipedia contributors. **Yarowsky algorithm.** Wikipedia, The Free Encyclopedia. August 20, 2020, 19:47 UTC. Available at: [https://en.wikipedia.org/w/index.php?title=Yarowsky\\_algorithm&oldid=974046729](https://en.wikipedia.org/w/index.php?title=Yarowsky_algorithm&oldid=974046729). Accessed November 2, 2020.
- William A. Gale, Kenneth W. Church, and David Yarowsky. **One sense per discourse.** In Proceedings of the workshop on Speech and Natural Language (HLT '91). Association for Computational Linguistics, USA, 233–237. 1992. DOI: <https://doi.org/10.3115/1075527.1075579>