

# Úvod do korpusové lingvistiky 3

1

AUTOMATICKÁ  
MORFOLOGICKÁ ANALÝZA  
(TOKENIZACE, LEMMATIZACE  
A TAGGING,  
DESAMBIGUAČE)

# Rozdíl mezi tokenem a slovem

2

- slovo
- slovoforma/slovní tvar/textové slovo
- grafická forma a jednotka parole
- slovo a interpunkce
- slovo a složený tvar
- slovo a spřežka

# Tokenizace

3

- V korpusové lingvistice automatický proces, který člení text složený z písmen, interpunkčních znamének a mezer na jednotlivé izolované tokeny, tj. na slovní tvary a interpunkční znaménka pro účely dalšího (obvykle počítačového) zpracování.
- Řetězce znaků definované znakové sady a definované oddělovače

# Příklad

*„Chcete-li mi to dát, neváhejte!“*

4

”  
Chcete

-  
li  
mi  
to  
dát

,  
neváhejte

!

“

# Velikost korpusu

5

## syn2015

Popis:

Synchronní reprezentativní korpus

Velikost:

120 748 715 pozic

Webová stránka:

<http://wiki.korpus.cz/doku.php/cnk:syn2015>

Štítky:

čeština reprezentativní synchronní řada SYN psaný

Dostupná metadata:

Atributy		Struktury	
word	1 751 599	<doc>	3 376
lc	1 426 255	<text>	114 492
lemma	777 011	<p>	2 805 065
lemma_lc	733 708	<s>	8 004 732
tag	3 529	<hi>	539 521
pos	12	<lb>	48 905
case	8		

# Pozice

6

- Tokeny/pozice – jednotky, v nichž se měří velikost korpusu.
- Podle počtu pozic se přibližně vypočítává počet textových slov (s opakováním).
- 120 748 715 pozic 100 milionů slovních tvarů
- word – různé slovní tvary
- lc – různé slovní tvary, ignoruje se velikost písma

# Lemma

7

- Textové slovo/systémové slovo
- Slovo jako jednotka textu
- Slovo jako lexikální jednotka
- Lemma – základní tvar – reprezentativní tvar
- Reprezentativní slovníková podoba, která je při automatickém zpracování jazyka v procesu lemmatizace přidělována každé formě v korpusu.

# Lemmatizace

8

- Přiřazení lemmatu jednomu slovnímu tvaru (příp. skupině slovních tvarů) v textu.
- Může být součástí morfologické analýzy
- slovnímu tvaru se přiřadí všechna jeho lemmata nezávisle na kontextu (pro homonymní tvar může být takových lemmat více)

## Příklad

*Jí je špatně. Já sním o Vánocích všechno.*

9

- |            |            |
|------------|------------|
| • jí       | jíst/ona   |
| • je       | být/ono    |
| • špatně   | špatně     |
| • .        | .          |
| • já       | já         |
| • sním     | sníst/snít |
| • o        | o          |
| • vánocích | vánoce     |
| • všechno  | všechno    |
| • .        | .          |

# Disambiguace

10

- V případě víceznačného výsledku je součástí lemmatizace [disambiguace](#) (zjednoznačnění) slovních tvarů v textu, kdy se náležité lemma stanoví z nabídky, kterou poskytla morfologická analýza, na základě kontextu.
- Problém disambiguace mnohdy nelze vyřešit na základě jazykového kontextu.

# Lemmatizátor

11

- Počítačový program, který provádí automatickou lemmatizaci .
- Je buď samostatný, n. je modulem morfologické analýzy, či morfologického [taggeru](#) provádějícího morfologickou [disambiguaci](#) textu.

# Význam lemmatizace

12

- umožní uživateli pracovat nikoli jen se slovními tvary, nýbrž i s lemmaty jakožto reprezentanty příslušných lexémů a jejich paradigm
- usnadňuje práci s korpusem
- umožňuje pracovat s korpusem na vyšší rovině abstrakce

# tag

13

- Morfologická značka (běžně nazývaná **tag**) je summarizací gramatické informace o hledaném slovu (pozici) v konkrétním kontextu. Možné tagy pro každý token se přiřazují na základě morfologické analýzy, výsledný tag je pak pro každý token vybrán během následné desambiguace.

# Tagger

14

- Počítačový program provádějící morfologickou [disambiguaci](#) textu, která je součástí [anotace textu](#) (obvykle v [korpusu](#)). K dispozici je: (a) **stochastický tagger** (statistický), který provádí disambiguaci na základě [strojového učení](#) ([Hajič & Hladká, 1997](#); [Hajič & Hladká, 1998](#); [Brants, 2000](#); [Votrubec, 2005](#)), n. (b) **tagger založený na lingvistických pravidlech**, která bud' vytváří lingvista ([Karlsson & Voutilainen ad. \(eds.\), 1995](#); [Tapanainen & Voutilainen, 1994](#); [Oliva & Hnátková ad., 2000](#); [Květoň, 2006](#); [Petkevič, 2006](#)), n. se automaticky vyvozuje z textů ([Brill, 1992](#)), n. (c) **hybridní tagger**, který spojuje výhody přístupů (a) a (b) ([Hajič & Krbec ad., 2001](#); [Jelínek & Petkevič, 2011](#)). Na výsledky činnosti t. obvykle navazuje program na syntaktickou analýzu textu, [parser](#). Někdy je t. součástí parseru.

# Příklad pos tagů

*Jí je špatně. Já sním o Vánocích všechno.*

15

- jí                   jíst/V/ona/P
- je                   být/V/ono/P
- špatně            špatně/D
- .                   ./Z
- já                   já/P
- sním              sníst/V/snít/V
- o                   o/R
- vánocích          vánoce/N
- všechno           všechno/P
- .                   ./Z

# Většinou je vše v pořádku

16

vyrazit - říkala , že se obléká , ale že **jí/P je/V špatně/D** . Když stále nešla , volal jsem jí znovu .  
v deset v práci , další říkala sestře , že **jí/P je/V špatně/D** , že bere inzulin , ale nemá ho s sebou  
svědků bydlících v okolí . „ Řekl jsem , že **jí/P je/V špatně/D** ... “ Útok žirafy Americká vědkyně Katy Williams a její  
„ čuchněte si , slečno ! “ a že **jí/P je/V špatně/D** a kolena že má rozedraná tak hrůzně , že mi  
mě poprosila , abych to vzala za ni , protože **jí/P je/V špatně/D** . Udělala jsem jenom to , co po mně chtěla  
probudila před svítáním . Její první myšlenka byla , že **jí/P je/V špatně/D** , protože jí zprostřed břicha vycházel silný pocit nevolnosti .  
Volala mu na mobil , aby hned přijel , že **jí/P je/V špatně/D** a kドovíco ještě . Prostě ho ukecala . Šel nahoru  
ní ale alkohol necítili a sama jim řekla , že **jí/P je/V špatně/D** a je diabetička . Ženu se podařilo zachránit včas .  
; krmí se sama ; přejedením si způsobí , že **jí/P je/V špatně/D** ; má strach , že bude muset přerušit kojení dítěte  
se bála , že nastydne , si myslí , že **jí/P je/V špatně/D** od srdce – navzdory tomu , že Naděžda Pavlovna trpěla  
snad pět let a když zrovna neřídí auto , tak **jí/P je/V špatně/D** i při pětiminutové jízdě . Nešikovně a nezkušeně jsem  
nemá kříčet . Po aktu žena nabulíkovala pachateli , že **jí/P je/V špatně/D** a aby otevřel okno . " Dívka v nestřezeném okamžiku  
, která uvařila kávu ženě , jež tvrdila , že **jí/P je/V špatně/D** , přišla o pět tisíc korun . Cesty mohou být

# Občas se vloudí chyby

17

- MF plus určuje a třídí . A přestože zná snad všechny , **jí/on/P je/být/V jenom** málokdy . „ Mě už na to neužije ,
- Sestry sudičky nemytého uprchlíka , jak se láduje zbytky z kuřete , **jí/on/P je/být/V přímo** z talíře v lednici . Dospěla nakonec k názoru
- Týden , ve Znojmě mají problémy s pravidelnou konzumací ryb ( **jí/on/P je/být/V jen** 33,1 % lidí ) . V Plzni mají ryby

" **Já/já/P sním/snít/v o/o/R vánocích/vánoce/N bílých** , kdy každé přání splnilo se nám

# *Místo vašich schůzek sis měl lépe vybírat*

18

trvání oprav bude příjezd do zámku zcela znemožněný autům . **Místo/místo/R** *oprav bude* označené a ohraničené zábranami . Vstup do areálu Bučicích . V ulici Nová budou prováděny úpravy silnice . **Místo/místo/R** *oprav bude* důkladně označeno . Cyklostezku dokončí letos Zruč nad

# Výhody lemmatizace

19

- Všechny tvary určitého lexému vyhledáme i bez lemmatizace:
- [lc="pes|ps([auiyů])|em|ům|ech|ovi|ové"]
- [lemma="pes"]
- Pokud budeme chtít hledat všechna maskulina životná, která končí v nominativu sg. na s a skloňují se podle typu *pán*, bez lemmatizace a taggování to nepůjde.

# Tagset

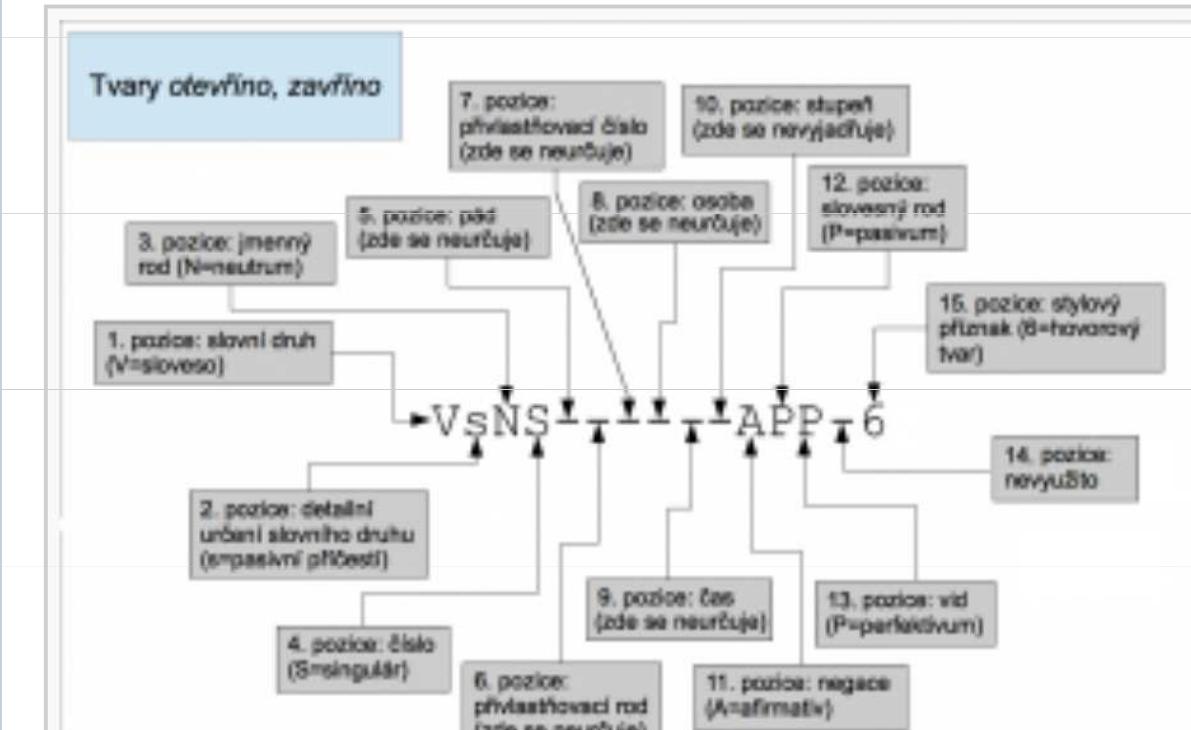
20

- Poziční atributový
- Gramatické vlastnosti, jako např. slovní druh, rod, číslo, pád, osoba, ..., se značují a) na určité pozici nebo b) jsou pojmenovány určitým atributem.
- Gramatické významy jako např. substantivum, maskulinum, plurál, genitiv, 1. osoba, ..., jsou vyjádřeny závazně a) na určité pozici nebo b) za odpovídajícím atributem.

# poziční značka

21

## Struktura značky



Popis tagu odpovídajícího slovním tvarům **otevříno**,  
**zavříno** v korpusu **SYN2020**



# Poziční systém tagu

22

**Vlastní...** cesty do Kraslic . **Mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----**, cítím se špatně . Nečekal jsem ním kouskem minulého roku nebo prvním nového . **Mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----**. Každé dopoledne čekám za jsem se , že jsou ještě i levné požitky . **Mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----**. Jsem tu sám , skládám odvezat a ujistit je , že jsem v pořádku a **mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----**. 12 . 15 : Jedna protivná servírka řekla : " Výběc nejsem naštvaná , " odpověděla naštvaně . " **Mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----** a jsem v pohodě . " No jistě , a Wezr roztrhl obálku a četl : " Milá tetinko , **mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----** a posílám ty věci , už je nepotřebuješ . " " **Mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----** , " řekl Wesley . " Když - no , " Zaklonila hlavu , aby na něj viděla . " **Mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----**. A ty se máš ? " " Výborně . Zamumlácosi jako , že se má dobře , **mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----**, protože mám přítelkyni , kterou jsem měl . " Sijambo , " odpověděla Nikola . " **Mám/mít/VB-S---1P-AAI-- se/se/P7-4----- dobře/dobře/Dg-----1A-----**. " " Tak už mám dva žáky , "

# Atributový systém tagu

23

ryky na téma "jak se máš?</s><s>- děkuju,	<b>mám</b> mít/k5eAalmlp1nS	<b>se</b> se/k3xPyFc4	<b>dobře</b> dobře/k6eAd1	a jak se máš ty?</s><s>" byly vzhledem k
vičení.</s><s>Teď se to všechno obrátilo,	<b>mám</b> mít/k5eAalmlp1nS	<b>se</b> se/k3xPyFc4	<b>dobře</b> dobře/k6eAd1	a fitness mě živí," říká Filip Šteflovič o své
m, že jsem poslední... no neva Tak čauky,	<b>mám</b> mít/k5eAalmlp1nS	<b>se</b> se/k3xPyFc4	<b>dobře</b> dobře/k6eAd1	, jen se trochu už s těma staroušema nudí
z dět na mé váze.</s><s>Je to sice pravda,	<b>mám</b> mít/k5eAalmlp1nS	<b>se</b> se/k3xPyFc4	<b>dobře</b> dobře/k6eAd1	, ale kila mě trápila stále.</s><s>Celý můj
ě rádi."</s><s>anketa,návštěvníci plesu: "	<b>Mám</b> mít/k5eAalmlp1nS	<b>se</b> se/k3xPyFc4	<b>dobře</b> dobře/k6eAd1	zpívám Karla Gota a Petra Muka, jinak nic.
Maminko NE!!!</s><s>7. týden:Maminko,	<b>mám</b> mít/k5eAalmlp1nS	<b>se</b> se/k3xPyFc4	<b>dobře</b> dobře/k6eAd1	.</s><s>Jsem v nebíčku... Strašně mi chyt
i nadpřirozeného rádu.</s><s>"Maminko,	<b>mám</b> mít/k5eAalmlp1nS	<b>se</b> se/k3xPyFc4	<b>dobře</b> dobře/k6eAd1	.</s><s>Jsem v nebíčku..." Otázka možno:

## Různé korpusu a různé jazyky používají různé tagsety

24

- [https://wiki.korpus.cz/doku.php/cnk:intercorp:verze10#morfosyntakticka anotace](https://wiki.korpus.cz/doku.php/cnk:intercorp:verze10#morfosyntakticka_anotace)
- <https://www.sketchengine.eu/German-rftagger-part-of-speech-tagset/>
- [http://utkl.ff.cuni.cz/%7Erosen/public/stts guide.pdf](http://utkl.ff.cuni.cz/%7Erosen/public/stts_guide.pdf)

# Araneum Francogallicum Minus (French, 15.03) 120 M

25

ce ballet orchestré à Agadez puis Niamey . L' on	<b>parle</b> /parler/VER:pres	d' une demande d' amnistie individuelle émanant de notre front
laisser la place aux multinationales ? Au moment où on	<b>parle</b> /parler/VER:pres	de traduire les responsables Guinéens auteurs des crimes et viols
en France de 1875 , les alternatives dont nous allons	<b>parler</b> /parler/VER:infi	au cours de ce séminaire apparaissent dans le système pénal
de dyslexie souffrant de légers troubles de la vue ne	<b>parlant</b> /parler/VER:ppre	pas français couramment . A ce jour là , BrowseAloud
sur le mot " diaporama " ! : Observons et	<b>parlons</b> /parler/VER:pres	de tout ce qui concerne notre planète et son humanité
et se pose continuellement des questions : " De quoi	<b>parle</b> /parler/VER:pres	l' histoire ? Que va-t-il arriver maintenant ? A quoi
qui se battent dans le parking du Fuzzy . On	<b>parle</b> /parler/VER:pres	encore de la légendaire bataille de Lacolle . On sait
héritage et une affirmation tragique de son existence , Marcel	<b>parle</b> /parler/VER:pres	! Il parle de son enfance , sans père ,
affirmation tragique de son existence , Marcel parle ! Il	<b>parle</b> /parler/VER:pres	de son enfance , sans père , dans une famille
monologue absurde , naïf , ironique et poétique , Marcel	<b>parle</b> /parler/VER:pres	aussi de ses peurs imaginaires et des dangers réels en

# Araneum Germanicum Minus (German, 15.02) 120 M

26

erforderlich Argumente und Ziele die für den Erhalt des Bahnhofs **sprechen/sprechen/VVINF** „ Hier Brilon-Wald , hier Brilon-Wald ! “ bekannter Bahn

Theorie selbst erfassen , mit denen man also über Theorien **spricht/sprechen/VVFIN** . Definition 2.6 . Metatheoretische Begriffe Begriffe mi

eteoristische Begriffe Begriffe mit denen man über Eigenschaften von Theorien **spricht/sprechen/VVFIN** werden metatheoretische Begriffe genannt . 2.3 .3 . OI

die Sprache , mit der eine Wissenschaft über ihre Gegenstände **spricht/sprechen/VVFIN** . Betrachten wir zunächst die Verwendung der Wissen

Chemiker , z.B. , verwendet Sprache um über Gegenstände zu **sprechen/sprechen/VVINF** , die keine Sprache sind . Die Sprache , die

verwendet . Er verwendet Sprache , um über Gegenstände zu **sprechen/sprechen/VVINF** , die selbst nicht Sprache sind . Die Sprache ,

Sprache , mit der man über nicht-sprachliche Gegenstände einer Wissenschaft **spricht/sprechen/VVFIN** , wird Objektsprache genannt . Der Wissenschaftler ve

Wissenschaftler verwendet Sprache jedoch auch , um über Sprache zu **sprechen/sprechen/VVINF** , z.B. über die Objektsprache seiner Wissenschaft . Da

2.8 . Metasprache Jede Sprache mit der über eine Sprache **gesprochen/sprechen/VVPP** wird , ist eine Metasprache Da eine Metasprache selbs

Man kann in der Metasprache über alle Beschaffenheiten ihrer Objektsprache **sprechen/sprechen/VVINF** . Man kann in der Metasprache Regeln für den Gebrau

# Příklad otázek v testu

27

- Vyjmenuj jednotlivé kroky automatického zpracování textu, jejichž výsledkem je lemmatizovaný a morfologicky taggovaný text.
- Jak zjistíme velikost korpusu?
- Uved'te příklady, kdy jeden slovní tvar lze interpretovat vícelemmaty.
- Uved'te příklady, kdy jeden slovní tvar lze interpretovat jediným lemmatem, ale má více významu gramatických kategorií pádu a čísla.