

Morfologie

Morfologie, morfologická analýza

Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/nlp_intro/

Obsah:

- ▶ Morfologie
- ▶ Morfologická analýza

- ▶ nauka o stavbě a tvorbě slov (v daném jazyce)
- ▶ **morfém** – nejmenší jednotka, která může **nést** význam

pří-lež-it-ost-n-ými

základní tvar = **příležitostný**
 příd. jméno, rod muž. živ., neživ., žen. nebo stř., 7. pád, mn. č.

pří – prefix (*blízko*)
lež – lexikální kořen (*ležet*)
it – adjektivní derivační sufix (*ten, který*)
ost – substantivní derivační sufix (*ta skutečnost, že*)
n – adjektivní derivační sufix (*charakteristický pro*)
ými – gramatický afix (*instrumentál plurálu*)

Základní lingvistické termíny v morfologii

- ▶ **slovní druh** (*part of speech*) – podstatné jméno (*substantivum*), přídavné jméno (*adjektivum*), sloveso (*verbum*), příslovce (*adverbium*), ...
- ▶ (gramatický) **pád** (*case*) – *nominativ, genitiv, dativ, akuzativ, vokativ, lokál, instrumentál*
- ▶ **číslo** (*number*) – *singulár, plurál*
- ▶ **rod** (*gender*) – 4 rody, mužský (*masculinum*) životný a neživotný (*animativní* a *inanativní*), ženský (*femininum*) a střední (*neutrum*)
- ▶ slovotvorba – **předpona** (*prefix*), **přípona** (*sufix*), předpona nebo přípona (*afix*)
- ▶ **základní tvar slova** – *lemma* (mn. č. *lemmata*)
- ▶ **ohýbání** slov (*flexe*) – skloňování (*deklinace*, podstatná jména, přídavná jména, zájmena a číslovky) a časování (*konjugace*, slovesa)
- ▶ **odvozování** slov a slovních tvarů – *derivování*

Dělení morfémů

dělení používané zejména v analytických jazycích (angličtina):

- ▶ morfém **obsahové** (*content*) × **funkční** (*function*)
- ▶ morfém **volné** (*free*) × **vázané** (*bound*)

dělení používané zejména ve flektivních jazycích (čeština):

- ▶ **kořeny** – nesamostatné morfémey nesoucí elementární lexikální významy
- ▶ **afixy**, které se dále dělí
 - podle funkce:
 - *gramatické/flektivní* – vyjadřují gramatické kategorie
 - *slovotvorné/derivační* – odvozování slov
 - podle postavení vzhledem ke kořeni:
 - *prefixy* – morfémey stojící před kořenovým morfémem (*pod-, anti-, v-*)
 - *sufixy* – morfémey připojované za kořenové morfémey (*-ík, -izmus, ...*)
 - *postfixy* – slovotvorné morfémey připojované až za gramatický sufix (*kdosi, kohokoli, ...*)
 - *circumfix* – morfémey připojované “kolem” základu, není v češtině
 - *infix, interfix* – morfémey vsazované dovnitř slova (*mal-il-inky, velk-o-město, ...*)

Procesy tvoření slov

dělení **morfologie** podle třech základních procesů tvoření slov:

- **flektivní morfologie** – popisuje strukturu slovních tvarů pomocí **flexe** (ohýbání – skloňování a časování)

| | | | |
|--------------|----------------|--------------|-------|
| 1 pes | 2 psa | 3 psovi, psu | 4 psa |
| 5 pse | 6 psovi, psu | 7 psem | |
| 1 psové, psi | 2 psů | 3 psum, psům | 4 psy |
| 5 psové, psi | 6 psách, psech | 7 psy, psama | |

- **derivativní (derivační) morfologie** – zkoumá **odvozování** slov

mýdlo: mydl-ář, mydl-ina, mýdel-ný, mydl-it, mýdél-ko

- **kompozicní (kompoziční) morfologie** – zachycuje tvoření slov pomocí **skládání**

ohni-vzdorný, pravdě-podobný, oka-mžik
tlako-měr, vodo-pád, děje-pis
samo-obsluha, malo-město, býlo-žravý

Derivační morfologie – vztah fundace

- **slovotvorný svazek/hnízdo** – souhrn slov fundovaných jedním slovem
mýdlo → mydl-ář, mydl-ina, mýdel-ný, mydl-it, mýdél-ko

- **slovotvorná čeleď** – souhrn všech příbuzných slov (se stejným kořenem)

les

- pra-les → pra-les-ní
- les-ní
 - lesn-ík → lesnic-ký → lesnic-tví
 - lesn-ice
 - nad-lesní
- les-ík → lesíč-ek

Derivační morfologie – vztah fundace

fundace – základní slovotvorný vztah

- slova neutvořená, prvotní, **fundující** – nemůžeme vysvětlit pomocí jiných slov jazyka
voda, hlava, vejce
- slova utvořená, **fundovaná** – opírají se o slova základová
trávník, růžový, učitel
- **fundace** – spojení slova základového se slovem utvořeným
mladý → mladík
- **slovotvorná řada** – opakované odvození až k prvotnímu slovu
rybníkářský ← rybníkář ← rybník ← ryba

Lexikální a gramatické kategorie

Morfologická analýza klasifikuje (značkuje, *tag*) slovní tvary jednotlivých kategorií (*Part of Speech/PoS tags*). Kategorie pro účely analýzy můžeme dělit na dvě skupiny:

- **lexikální kategorie** – pojmenovávají věci, akce, myšlenky
podstatná jména, slovesa, přídavná jména, příslovce, ...
- **gramatické kategorie** – vyjadřují vztahy mezi ostatními větnými členy
předložky, spojky, částice, anglické členy, ...

jazyky s { jednoduchou morfologií (angličtina) – několik desítek kategorií (*POS – Part of Speech* – slovní druhy)
bohatou morfologií – **hierarchický systém**, kde vedle základních slovních druhů určujeme nejrůznější subklasifikace (pád, číslo, rod, osoba, druhy příslovcí, ...) – celkově tisíce značek

Morfologická analýza

- ▶ rozpoznávání slovních tvarů
- ▶ nástroj se nazývá **morfologický analyzátor** (*Part-of-Speech/PoS tagger*)
- ▶ provádí **lemmatizaci** – přiřazuje k rozpoznaným slovním tvarům **základní tvar (lemma)**
- ▶ charakterizuje morfo-syntaktické vlastnosti nalezených slovních tvarů:
příležitostného
 1. <s> příležitostn-ého (mladý GcAa)
 - <l> příležitostný
 - <c> adje Man sg #4
 - <c> adje Man,Min,Neu sg #2
- ▶ kvalita morfologické analýzy ovlivňuje všechny následující analytické roviny

Anglické gramatické morfémey

- s** 3. osoba, jedn.č., přítomný čas
- ed** minulý čas
- ing** průběhový
- en** přičestí minulé trpné
- s** množné číslo
- 's** přivlastnění
- er** 2. stupeň přídavného jména (komparativ)
- est** 3. stupeň přídavného jména (superlativ)

Pro získání **základního tvaru** (pro indexování) často stačí *odsekávat koncovky (stemming)*

Morfologická analýza

Úkol morfologické analýzy zahrnuje 3 podúkoly:

- ▶ vypsat **všechny možné analýzy** – klasický **morfologický analyzátor**

```
<s> =svěž=í== (331-cizí)
<l>svěží
<c>k2eAgMnSc1d1 <c>k2eAgMnSc5d1 <c>k2eAgMnPc1d1 <c>k2eAgMnPc4d1
<c>k2eAgInSc1d1 <c>k2eAgInSc4d1 <c>k2eAgInSc5d1 ...
```
- ▶ vybrat **jednu nejpravděpodobnější analýzu** – **značkovač (tagger)**

Svěží vánek zanesl do naší vesnice příchut' jara.

```
<s>
Svěží svěží k2eAgInSc1d1
vánek vánek k1gInSc1 ...
```
- ▶ **analýzy pro neznámé slovo** podle koncovky – “**hádač**” (**guesser**)

memorizovatelnými:

 - ajka: –notfound
 - guesser: memorizovatelnými <l>memorizovatelný <c>k1gFnPc7

Automatické značkování

- ▶ **Part-Of-Speech Tagging**

```
The/DT girls/NNs learned/VVD basic/AJ martial/AJ arts/NNs poses/NNs.
```
- ▶ **učení** z trénovacích dat
 - **s dohledem** (supervised) – vzorové texty i značky
 - **bez dohledu** (unsupervised) – pouze texty
 - **s částečným dohledem** (semi-supervised) – texty a výstup morf.analyzátoru (s pravděpodobnostmi)

Brillův značkovač

- ▶ učí se podle trénovacích dat:
 1. přiřadí nejčastější značku
 2. zkontroluj, kde jsou chyby (podle trénovacích dat)
 3. ohodnotí pravidla pro opravu chyb → vyber nelepší → oprav zpětně chybné značky
 4. opakuj, dokud se daří odvozovat dobrá pravidla
- ▶ používá učení založené na transformacích (*transformation-based learning*)
- ▶ analogie – malování obrazu: nejprve pozadí a pak přes něj stále drobnější detaily
- ▶ značkuje 36 různých POS značek
- ▶ úspěšnost – přes 90 %

Brillův značkovač – příklad

| věta: | podle frekvence: | P1: | P2: | správně (zlatý standard): |
|----------------|------------------|-----|-----|---------------------------|
| The | at | | | at |
| President | nn-tl | | | nn-tl |
| said | vbd | | | vbd |
| he | pps | | | pps |
| will | md | | | md |
| ask | vb | | | vb |
| Congress | np | | | np |
| to | to | | | to |
| increase | nn | | vb | vb |
| grants | nns | | | nns |
| to | to | to | in | in |
| states | nns | | | nns |
| for | in | | | in |
| vocational | jj | | | jj |
| rehabilitation | nn | | | nn |
| . | . | | | . |

P1: Replace nn with vb when the previous word is to

P2: Replace to with in when the next tag is nns

Brillův značkovač – příklad

Loading tagged data...

Training unigram tagger: [accuracy: 0.820940]

Training Brill tagger on 37168 tokens...

Iteration 1: 1482 errors; ranking 23989 rules;

Found: "Replace POS with VBZ if the preceding word is tagged PRP"

Apply: [changed 39 tags: 39 correct; 0 incorrect]

Iteration 2: 1443 errors; ranking 23662 rules;

Found: "Replace VBP with VB if one of the 3 preceding words is tagged MD"

Apply: [changed 36 tags: 36 correct; 0 incorrect]

Iteration 3: 1407 errors; ranking 23308 rules;

Found: "Replace VBP with VB if the preceding word is tagged TO"

Apply: [changed 24 tags: 23 correct; 1 incorrect]

...

Iteration 21: 1128 errors; ranking 20569 rules;

Found: "Replace VBD with VBN if the preceding word is tagged VBD"

[insufficient improvement; stopping]

Brill accuracy: 0.835145

Algoritmický popis české formální morfologie

v češtině nestačí pravidla podle obecných morfémů – je potřebné mít lexikon, který ke každému kmenu obsahuje jeho přiřazení ke vzoru

morfologické (tvaroslovné) **paradigma** – soubor tvarů ohebného slova vyjadřující **systém** jeho **mluvnických kategorií**

vzor – reprezentace tvaroslovného paradigmatu paradigmatem určitého konkrétního slova

Algoritmický popis:

1. definice **koncovkových množin**
 2. definice vzorů prostřednictvím **vzorových slov** rozdělených na:
 - neměnná část vzorového slova – **kmenový základ**
 - proměnlivé části vzorového slova – **intersegmenty**
 - **koncovkové množiny** obsahující utřídité seznamy všech přípustných koncovek vzorového slova spolu s jejich gramatickými významy
- popis vzoru* = formální pravidlo, které specifikuje přípustné kombinace těchto komponent (segmentů) ohebného slova

Formát české morfologické databáze

slovník = lemma:vzor|poznámka

Luděk:Luděk|180.1

Vladěk:Luděk|180.1

hlemýžděk:Luděk|180.1

koncovkové množiny

| | |
|---------------|-----------------|
| =rs-mluv-S204 | =rs-mluv-S386 |
| {_, k1gMnSc1} | {ú, k1gMnPc2} |
| =rs-mluv-S99 | =rs-mluv-S499 |
| {i, k1gMnPc1} | {ovi, k1gMnSc3} |
| =rs-mluv-S102 | {ovi, k1gMnSc6} |
| {i, k1gMnPc5} | ... |

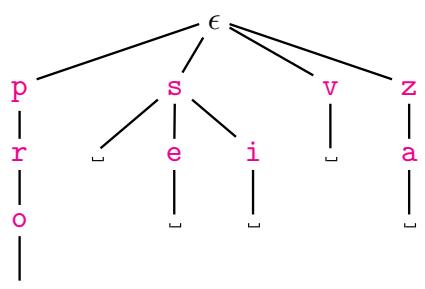
vzor

+Luděk

```
<děk> rs-mluv-S204
<d'c> rs-mluv-S99, rs-mluv-S102, rs-mluv-S385
<d'k> rs-mluv-S386, rs-mluv-S499, rs-mluv-S460,
       rs-mluv-konc12, rs-mluv-S510, rs-mluv-S74, rs-mluv-S71,
       rs-mluv-S294, rs-mluv-S521, rs-mluv-S522, rs-mluv-S163,
       rs-mluv-S171, rs-mluv-S299, rs-mluv-konc08
```

Efektivní implementace morfologického lexikonu – trie struktura trie:

- ▶ uspořádaný strom nad danou abecedou A
- ▶ v každém uzlu je různé písmeno z abecedy A
- ▶ klíč je v trie uložen jako cesta od kořene
- ▶ výhody:
 - sdílení společných prefixů
 - v každém případě nalezení nejdelšího shodného prefixu



Segmentace slova pro potřeby algoritmického popisu

► segmentace od začátku slova

- a) segmenty se snadno formalizovatelným výskytem vázaným gramaticky:

- negativní prefix ne-
- superlativní prefix nej-
- futurální slovesný prefix po-

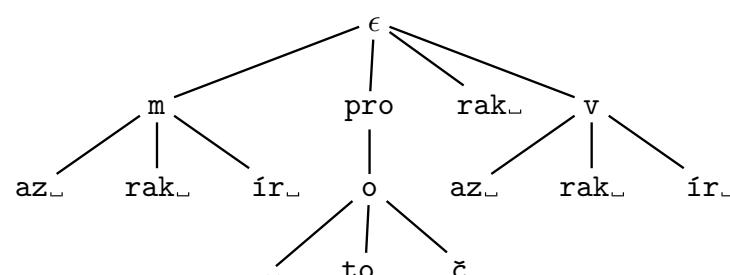
- b) segmenty s nesnadno formalizovatelným výskytem vázaným sémanticky:

- prefixy
- první členy kompozit
- prefixy ni-, ně- zájmen neurčitých a záporných

► segmentace od konce slova

- a) rozdelení slovního tvaru na kmen a koncovku
- b) další segmentace kmene na kmenový základ a intersegment

Eliminace cest v trie



Jiná efektivní implementace ML – konečný automat

- ▶ původně BP, Radovan Štancel, 2005 – doplňování diakritiky
- ▶ použití mírně pozměněných volně dostupných knihoven pro práci s KA od Jana Daciuka – [FSA library](#)
- ▶ vstupní data se generují ze slovníku [ajky](#) převedeného do tvaru "slovo<TAB>lemma<TAB>značka" (cca 33 mil. řádků)

```

Abcházce    Abcházec   k1gMnPc4
Abcházce    Abcházec   k1gMnSc2
Abcházce    Abcházec   k1gMnSc4
Abcházcem   Abcházec   k1gMnSc7
Abcházci    Abcházec   k1gMnPc1
Abcházci    Abcházec   k1gMnPc5
Abcházci    Abcházec   k1gMnPc7
Abcházci    Abcházec   k1gMnSc3
Abcházci    Abcházec   k1gMnSc6
...

```

Jiná efektivní implementace ML – konečný automat

- ▶ data se dále upravují pro KA – slovo+zkr.lemma+značky:
Abcházce+ACec+k1gMnPc4, k1gMnSc2, k1gMnSc4
Abcházcem+ADec+k1gMnSc7
Abcházci+ACec+k1gMnPc1, k1gMnPc5, k1gMnPc7, k1gMnSc3, ...
- ▶ v lemmatu – 1. písmeno je počet znaků, které se odtrhnují jako předpona, 2. písmeno je počet znaků, které se trhají od konce, a ostatní znaky se přidají
- ▶ tím se sníží počet řádků na 6.7 mil. řádků, ze kterých se přímo generuje (a minimalizuje) konečný automat
- ▶ výsledný slovník má 4.3 MB
- ▶ rychlosť je cca o 1/4 lepší než u trie, velikost řádově srovnatelná

České morfologické analyzátoře

- ▶ [ajka](#)
 - Radek Sedláček, FI MU Brno
 - <http://nlp.fi.muni.cz/projekty/ajka/>
 - značky jsou řetězce dvojic [atribut–hodnota](#)
 - napsaný v C, využívá struktury [trie](#)
 - 390 000 základních tvarů, 6 300 000 různých slovních tvarů, 15 000 různých značek, slovník 3.13 MB
 - rychlosť analýzy – cca 18 000 slov/s
 - v současnosti nový nástroj [majka](#) od Pavla Šmerka, na principu konečných automatů, s novým mechanizmem vzorů
<http://nlp.fi.muni.cz/ma>
- ▶ [pražský morfologický analyzátor](#)
 - Barbora Hladká, Jan Hajč a jeho tým, ÚFAL MFF UK Praha
 - <http://ufal.mff.cuni.cz/czech-tagging/>
 - používá [poziční značky](#)
 - "free" část napsaná v Perlu, menší slovník (cca 76 000 základních tvarů, 6 000 koncovek)
 - v současnosti nový neuronový analyzátor [morphodita](#)

Pražský morfologický analyzátor – poziční značky

| pozice | kategorie | anglicky | česky |
|--------|------------|--------------------------|-----------------|
| 1 | POS | Part of Speech | Slovní druh |
| 2 | SUBPOS | Detailed Part of Speech | Slovní poddruh |
| 3 | GENDER | Agreement Gender | Rod |
| 4 | NUMBER | Agreement Number | Číslo |
| 5 | CASE | Case | Pád |
| 6 | POSGENDER | Possessor's Gender | Rod vlastníka |
| 7 | POSSNUMBER | Possessor's Number | Číslo vlastníka |
| 8 | PERSON | Person | Osoba |
| 9 | TENSE | Tense | Čas |
| 10 | GRADE | Degree of Comparison | Stupeň |
| 11 | NEGATION | Negation (by prefix) | Negace |
| 12 | VOICE | Voice | Slovesný rod |
| 13 | RESERVE1 | Reserved for future use | Rezerva |
| 14 | RESERVE2 | Reserved for future use | Rezerva |
| 15 | VAR | Variant, Style, Register | Varianta, styl |

Pražský morfologický analyzátor – příklad

► vstup:

Prezident rezignoval na svou funkci.

► výstup:

```
<csts>
<f cap>Prezident<MMl>prezident<MMt>NNMS1----A----
<f>rezignoval<MMl>rezignovat_:T<MMt>VpYS---XR-AA---
<f>na<MMl>na<MMt>RR--4-----<MMt>RR--6-----
<f>svou<MMl>svůj-1_^(přivlast.)<MMt>P8FS4-----1
    <MMt>P8FS7-----1
<f>funkci<MMl>funkce<MMt>NNFS3----A----
    <MMt>NNFS4----A----<MMt>NNFS6----A----
<D>
<d>.<MMl>.<MMt>Z:-----
</csts>
```

Morfologický analyzátor ajka – příklad

► dávkově

Prezident <l>prezident <c>k1gMnSc1
rezignoval <l>rezignovat <c>k5eApMnStMmPaI <c>k5eApInStMmPaI
na <l>na <c>k7c4 <c>k7c6
svou <l>svůj <c>k3x0gFnSc4p3 <c>k3x0gFnSc7p3
funkci <l>funkce <c>k1gFnSc3 <c>k1gFnSc6 <c>k1gFnSc4

► interaktivně

<s> ne=snesiteln=ého== (1023)
<l>snesitelný
<c>k2eNgMnSc2d1
<c>k2eNgMnSc4d1 ...

► všechny tvary (ajka -a)

<s> =p=es== (1148)
<l>pes
<c>k1gMnSc1
pes psům psů psovi psovi psa psu psy psech pse psi psové

Značky morfologického analyzátoru ajka

značka = řetězec dvojic *atributHodnota*: k1gNnSc3

| | | |
|---|-----------------|---|
| k | slovní druh | 1 – podst. jméno, 2 – př. jméno, ... |
| g | rod | M – muž. životný, I – muž. neživotný, ... |
| n | číslo | S – jednotné, P – množné, D – duál |
| c | pád | 1, 2, ..., 7 |
| p | osoba | 1, 2, 3 |
| m | slovesný způsob | F – infinitiv, R – imperativ, ... |
| a | slovesný vid | P – dokonavý, I – nedokonavý |
| t | typ příslovcí | T – času, L – místa, M – způsobu, ... |
| x | typ spojky | C – souřadící, S – podřadící |

Morfologický analyzátor ajka – webové rozhraní

<http://nlp.fi.muni.cz/projekty/wwwajka/>

Výsledek morfologické analýzy - interaktivní režim

(*) - Vypiš všechny odvozené tvary

Analyzovaný tvar: stát

| Základní tvar | Segmentace | Číslo vzoru | Kategorie |
|---------------|------------|-------------|-----------|
| stát (*) | =st=á=t= | 1422-stát | k5eAaImF |
| stát (*) | =st=á=t= | 1587-vstát | k5eAaPmF |
| stát (*) | =stát== | 874-most | k1gInSc1 |
| | | | k1gInSc4 |

Analyzuj text: Analyzuj