# Morfologie, morfologická analýza

Aleš Horák

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

Obsah:

- Morfologie
- Morfologická analýza



## Morfologie

- 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 – podstatné jméno (*substantivum*), přídavné jméno (*adjektivum*), sloveso (*verbum*), příslovce (*adverbium*), ...
- pád – *nominativ*, *genitiv*, *dativ*, *akuzativ*, *vokativ*, *lokál*, *instrumentál*
- číslo – *singulár*, *plurál*
- rod – 4 rody, mužský (*masculinum*) životný a neživotný (*animativní* a *inanimativní*), 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*) a časování (*konjugace*)
- odvozování – *derivování*





# Dělení morfémů

dělení používané zejména v analytických jazycích (angličtina):

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

dělení používané zejména ve flektivních jazycích (čeština):

- **kořeny** – nesamostatné morfémy nesoucí elementární lexikální významy
- **afixy**, které se dále dělí
  - podle funkce:
    - *gramatické/flekční*
    - *slovotvorné/derivační*
  - podle postavení vzhledem ke kořeni:
    - *prefixy* – morfémy stojící před kořenovým morfémem (pod-, anti-, v-)
    - *sufixy* – morfémy připojované za kořenové morfémy (-ík, -izmus, ...)
    - *postfixy* – slovotvorné morfémy připojované až za gramatický sufix (kdosi, kohokoli, ...)
    - *circumfix* – morfémy připojované "kolem" základu, není v češtině
    - *infix*, *interfix* – morfémy vsazované dovnitř slova (mal-il-inký, 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

- kompozicionální (kompoziční) morfologie – zachycuje tvoření slov pomocí skládání

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





# 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

# 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





# 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





# 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 příchuť 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`

# Anglické gramatické morfémy

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





# Brillův značkovač

- učí se podle trénovacích dat:
  1. přiřaď nejčastější značku
  2. zkontroluj, kde jsou chyby (podle trénovacích dat)
  3. ohodnoť 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: | zlatý standard: | podle frekvence: | P1: | P2: |
|---|---|---|---|---|
| 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 | vb | nn | vb | |
| grants | nns | nns | | |
| to | in | to | to | 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 utříděné seznamy všech přípustných koncovek vzorového slova spolu s jejich gramatickými významy

   *popis vzoru* = formální pravidlo, které specifikuje přípustné kombinace těchto komponent (segmentů) ohebného slova





# 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 vázáným sémanticky:
     - prefixy
     - první členy kompozit
     - prefixy `ni-`, `ně-` zájmen neurčitých a záporných
- segmentace **od konce slova**
  a) rozdělení slovního tvaru na **kmen** a **koncovku**
  b) další segmentace kmene na **kmenový základ** a **intersegment**

# České morfologické analyzátory

- `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 3.13MB
  - rychlost analýzy – cca 18 000 slov/s
  - v současnosti nový nástroj **majka** od Pavla Šmerka, na principu konečných automatů, s novým mechanizmem vzorů
- pražský morfologický analyzátor
  - Barbora Hladká, Jan Hajič 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)





# 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 | POSSGENDER | 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>
```





# 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 – 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>k3xOgFnSc4p3 <c>k3xOgFnSc7p3
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 psem psa psu psy psech pse psi psové
```





# Morfologický analyzátor ajka – webové rozhraní

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

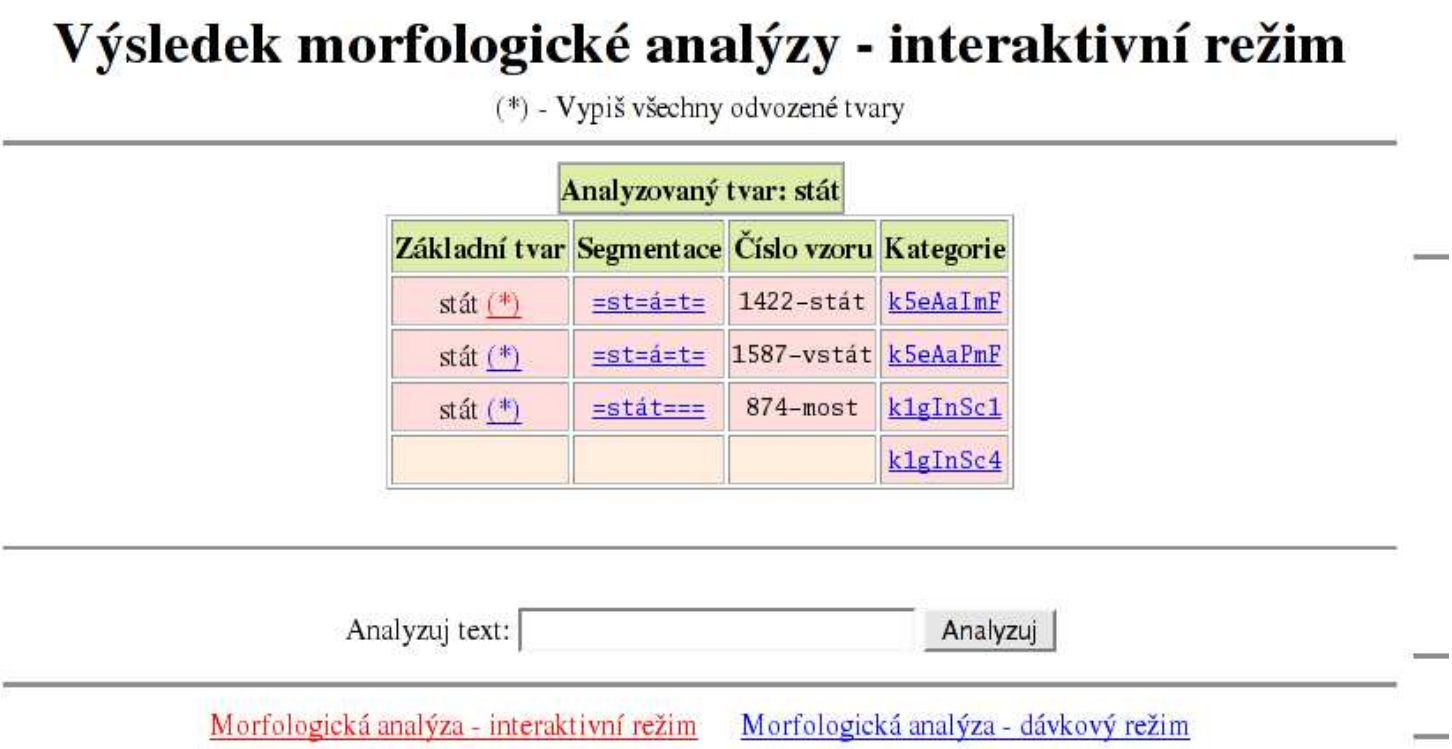

**Výsledek morfologické analýzy - interaktivní režim**

(*) - 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

Morfologická analýza - interaktivní režim Morfologická analýza - dávkový režim

# 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**

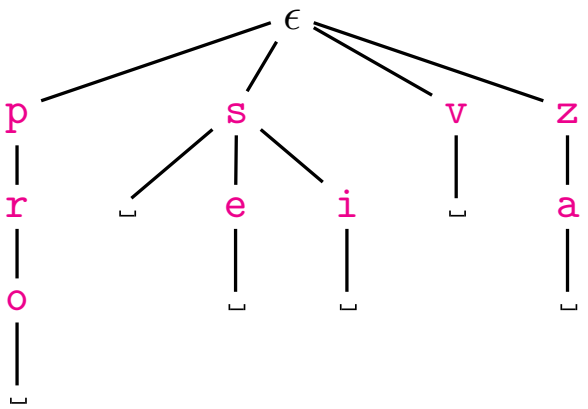






# Eliminace cest v trie

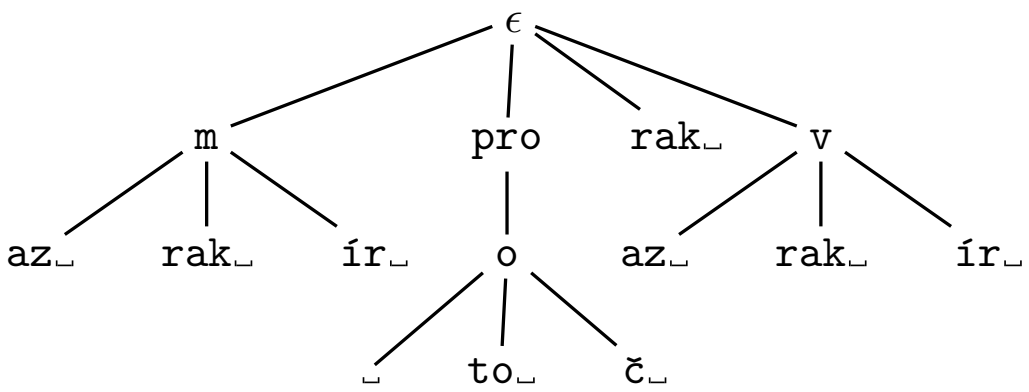

# Jiná efektivní implementace ML – konečný automat

- 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 odtrhnou 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 4.3MB
- rychlost je cca o 1/4 lepší než u trie, velikost řádově srovnatelná