

IB047

Morfologické a syntaktické značkování korpusů

Pavel Rychlý

pary@fi.muni.cz

5 April 2024

- každý token – značka
- několik desítek až tisíc značek (obsahující gramatické kategorie)
- Universal Tagset (Google)
 - 12 značek – pouze slovní druhy
- jeden sloupec ve vertikálním tvaru

Universal Dependencies

- nástupce Universal Tagset
- verze 2.13 (11/2023): 259 korpusů, 148 jazyků
- 14 značek – slovní druhy (+ 3 ostatní)
- open class
ADJ: adjective, ADV: adverb, INTJ: interjection, NOUN: noun, PROPN: proper noun, VERB: verb
- closed class
ADP: adposition, AUX: auxiliary, CCONJ: coordinating conjunction, DET: determiner, NUM: numeral, PART: particle, PRON: pronoun, SCONJ: subordinating conjunction
- ostatní
PUNCT: punctuation, SYM: symbol, X: other
- 21 features
PronType, Gender, Animacy, Number, Tense, Abbr, ...

Universal Dependencies

```
# newpar id = vesm9211-001-p7
# sent_id = vesm9211-001-p7s1
# text = Všechny tři světy si vzájemně trvale povídají a ovlivňují
# orig_file_sentence vesm9211_001#8
Všechny    DET      Animacy=Inan|Case=Nom|Gender=Masc|Number=Plur|
tři        NUM      Case=Nom|Number=Plur|NumForm=Word|NumType=Card
světy      NOUN     Animacy=Inan|Case=Nom|Gender=Masc|Number=Plur|
si         PRON     Case=Dat|PronType=Prs|Reflex=Yes|Variant=Short
vzájemně  ADV      Degree=Pos|Polarity=Pos
trvale     ADV      Degree=Pos|Polarity=Pos
povídají   VERB     Aspect=Imp|Mood=Ind|Number=Plur|Person=3|Polar
a          CCONJ    -
ovlivňují  VERB     Aspect=Imp|Mood=Ind|Number=Plur|Person=3|Polar
se         PRON     Case=Acc|PronType=Prs|Reflex=Yes|Variant=Short
```

Brněnské značky

- značka tvořena sadou znakových párů: atribut-hodnota
- atribut malým písmenem (k,g,n,c,p,x,w)
- hodnota velkým písmenem nebo číslicí
- k1 - k9, k0 – standardní slovní druhy ze ZŠ/SŠ
- kl – interpunkce
- k1glnSc4 = podstatné jméno, rod mužský neživotný, jednotné číslo, 4. pád
- korpus Desam

Morfologické značkování češtiny

Brněnské značky

Z	z	k7c2
téměř	téměř	k6xMd1
tří	tři	k4xCgFnPc2
desítek	desítka	k4xNgFnPc2
smluv	smlouva	k1gFnPc2
upravujících	upravující	k2gFnPc2d1
vztahy	vztah	k1gInPc4
mezi	mezi	k7c7
oběma	dva	k4xCgInPc7
subjekty	subjekt	k1gInPc7
celního	celní	k2gMnSc2d1
soustátí	soustátí	k1gNnSc2
jsou	být	k5mItPp3nPaI
okamžitě	okamžitě	k6xMd1
vypověditelné	vypověditelný	k2gFnPc1d1
všechny	všechn	k3xUgFnPc1
.	.	kI

Pražské značky

- různé formáty používané na ÚFAL MFF UK
- zejména v Prague Dependency Treebank (PDT)
- základní formát: poziční – 15 atributů dle pořadí

Pražské značky

Všechny	všechn	PLIP1-----
tři	tři	ClXP1-----
světy	svět	NNIP1-----A----
si	se	P7-X3-----
vzájemně	vzájemně	Dg-----1A----
trvale	trvale	Dg-----1A----
povídají	povídat	VB-P---3P-AA---
a	a	J^-----
ovlivňují	ovlivňovat	VB-P---3P-AA---
se	se	P7-X4-----
.	.	Z:-----

- morfologická databáze slov
- u každého slova: základní tvar (lemma), značka
- různé funkce – různé datové formáty
- generováno ze slovníku a popisu vzorů
- použití konečného automatu
- <https://nlp.fi.muni.cz/ma/>


příklad pro analýzu: vstup=*slovo*, výstup=*lemma+značka*

```
ježek:A:k1gMnSc1    <-- ježek:ježek:k1gMnSc1  
ježka:Cek:k1gMnSc2 <-- ježka:ježek:k1gMnSc2  
ježka:Cek:k1gMnSc4 <-- ježka:ježek:k1gMnSc4  
krtek:A:k1gMnSc1    <-- krtek:krtek:k1gMnSc1  
krtka:Cek:k1gMnSc2 <-- krtka:krtek:k1gMnSc2  
krtka:Cek:k1gMnSc4 <-- krtka:krtek:k1gMnSc4
```


Morfologický analyzátor majka

Velká data převedena do konečného automatu

- non-minimalized deterministic automaton for the example data



- minimalized deterministic automaton for the same data




Statistické informace

dictionary	lines	source MB	dictionary MB	bytes/line
w	13,609,590	186	3.3	0.240
w → l	14,101,767	240	4.0	0.287
w → l+t	80,303,929	2,478	4.4	0.054
w → w	957,464,060	19,993	6.1	0.006

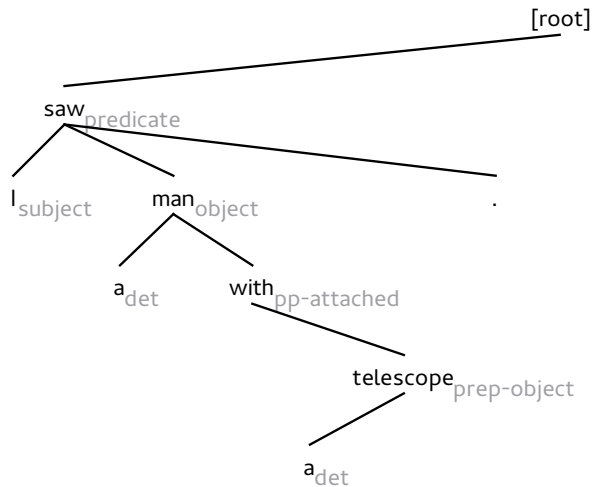
- základní tvar = heslo ve slovníku
- slovní druh
- další morfologické tvary slova
- časté použití (např. *většinou v množném čísle*)

- pro každou větu vytvoříme strom zachycující vztahy mezi slovy a/nebo skupinami slov
- frázový (složkový)
postupně ze slov vytváříme skupiny
- závislostní
určujeme závislosti mezi jednotlivými slovy
- řádově náročnější problém:
dokumentace často na stovkách stran

Phrase structure formalism – example



Dependency formalism – example



Dependency vs. phrase-structure

Non-projectivity

- disconnected phrases
- not natural in the phrase structure notation
- 20% of Czech sentences are reported to contain a non-projective dependency

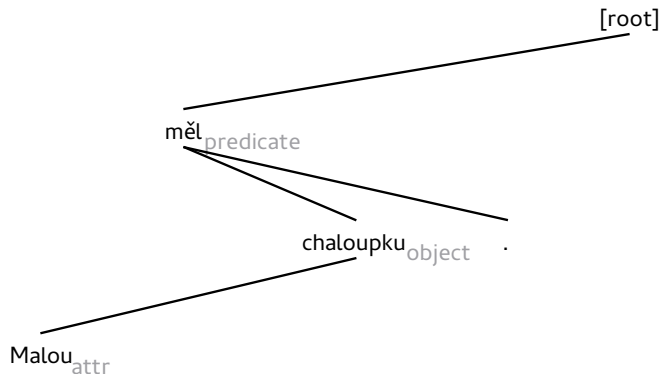
Phrase structure – more fine-grained analysis

- (new (queen of beauty))
- (new generation)(of fighters)


Coordinations and other “flat” phenomena

- not natural in the dependency notation
- problem for dependency analysis

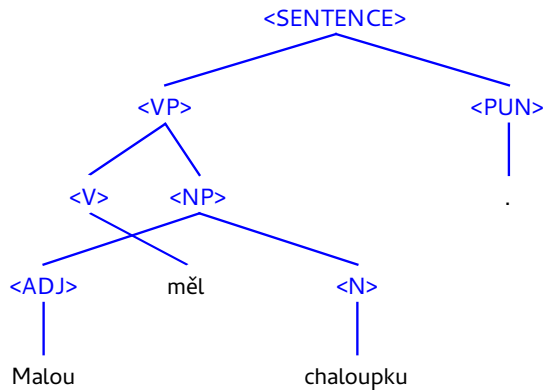
Non-projectivity – example




Non-projectivity in phrase structure formalism




Non-projectivity in phrase structure formalism





Non-projectivity in phrase structure formalism




Phrase structure expressivity



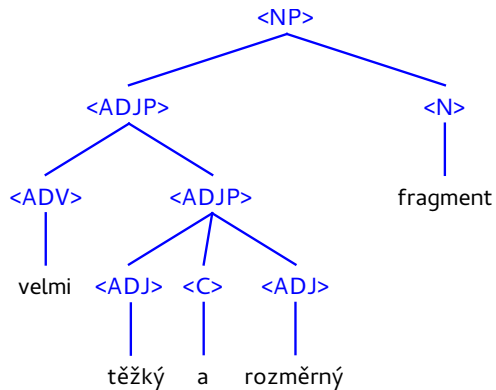
Phrase structure expressivity



Coordinations – dependency structure



Coordinations – phrase structure



- složkový systém:
 - fráze jako struktury – `<phr>`, `</phr>`
 - typy jako atributy
- závislostní systém:
 - očíslování tokenů, odkazy na tokeny
 - typy relací v dalším atributu

Záznam syntaxe v korpusu

Složkový systém: Penn Treebank

```
( (S (NP *)
  (VP Show
    (NP me)
    (NP (NP (NP all)
      the nonstop flights
      (PP (PP from
        (NP Denver))
        (PP to
          (NP San Francisco))))))
  (S (NP *)
    (VP leaving
      (NP about
        three
        o'clock
        (PP in
          (NP the afternoon))))))
.)
```

Záznam syntaxe v korpusu

Složkový systém: Susanne

A01:0260.27	NN1c	Implementation	[O[S[Ns:S.
A01:0260.30	IO	of	[Po.
A01:0260.33	NP1p	Georgia	[Ns[G[Nns.Nns]
A01:0260.39	GG	+<apos>s	.G]
A01:0270.03	NN1c	automobile	[Ns.
A01:0270.06	NN1n	title	.Ns]
A01:0270.09	NN1n	law	.Ns]Po]Ns:S]
A01:0270.12	YG	-	[c121.c121]
A01:0270.15	VBDZ	was	[Vsp.
A01:0270.18	RR	also	[R:G121.R:G121]
A01:0270.21	VVnt	recommend	.Vsp]
A01:0270.24	I Ib	by	[Pb:a.
A01:0270.27	AT	the	[Ns.
A01:0270.30	JJ	outgoing	.
A01:0270.33	NN1c	jury	.Ns]Pb:a]S]
A01:0270.39	YF	+	.O]

Závislostní systém: PDT (Universal Dependencies)

```
# orig_file_sentence vesm9211_001#8
1   Všechny   DET      3   det
2   tři      NUM      3   nummod
3   světy    NOUN     7   nsubj
4   si       PRON     7   obl:arg
5   vzájemně ADV      7   advmod
6   trvale   ADV      7   advmod
7   povídají VERB     0   root
8   a        CCONJ    9   cc
9   ovlivňují VERB     7   conj
10  se       PRON     9   obj
11  .        PUNCT    7   punct
```