

IB047

Morfologické a syntaktické
značkování korpusů

Pavel Rychlý

pary@fi.muni.cz

24. Březen 2025

Morfologické značkování

- 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 se
# orig_file_sentence vesm9211_001#8
Všechny    DET    Animacy=Inan|Case=Nom|Gender=Masc|Number=Plur|Person=3|Polar
tři        NUM    Case=Nom|Number=Plur|NumForm=Word|NumType=Cardinal
světy     NOUN   Animacy=Inan|Case=Nom|Gender=Masc|Number=Plur|Person=3|Polar
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
```

Morfologické značkování češtiny

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
- k1gInSc4 = 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	všechen	k3xUgFnPc1
.	.	kI

Morfologické značkování češtiny

Pražské značky

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

Morfologické značkování češtiny

Pražské značky

Všechny	všechen	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:-----

Morfologický analyzátor majka

- 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/>

Morfologický analyzátor majka

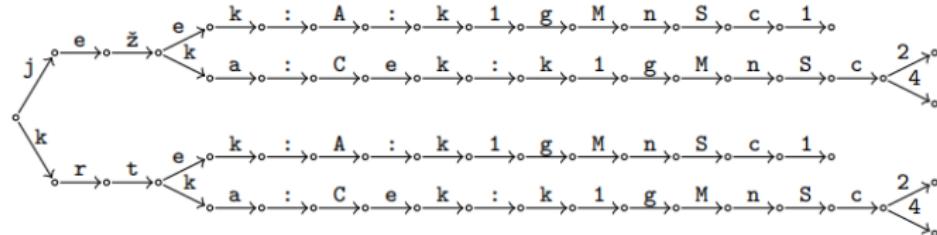
příklad pro analýzu: vstup=*slovo*, výstup=lemma+značka

```
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
```

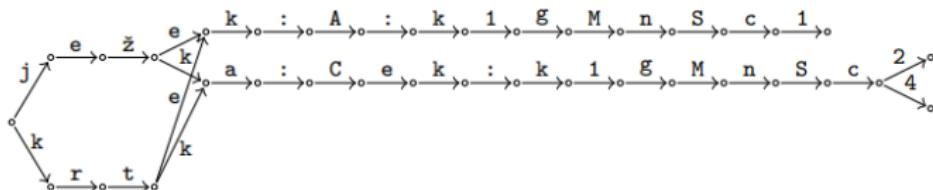
Morfologický analyzátor majka

Velká data převedena do konečného automatu

- non-minimized deterministic automaton for the example data



- minimalized deterministic automaton for the same data



Morfologický analyzátor majka

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

Použití pro slovníky

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

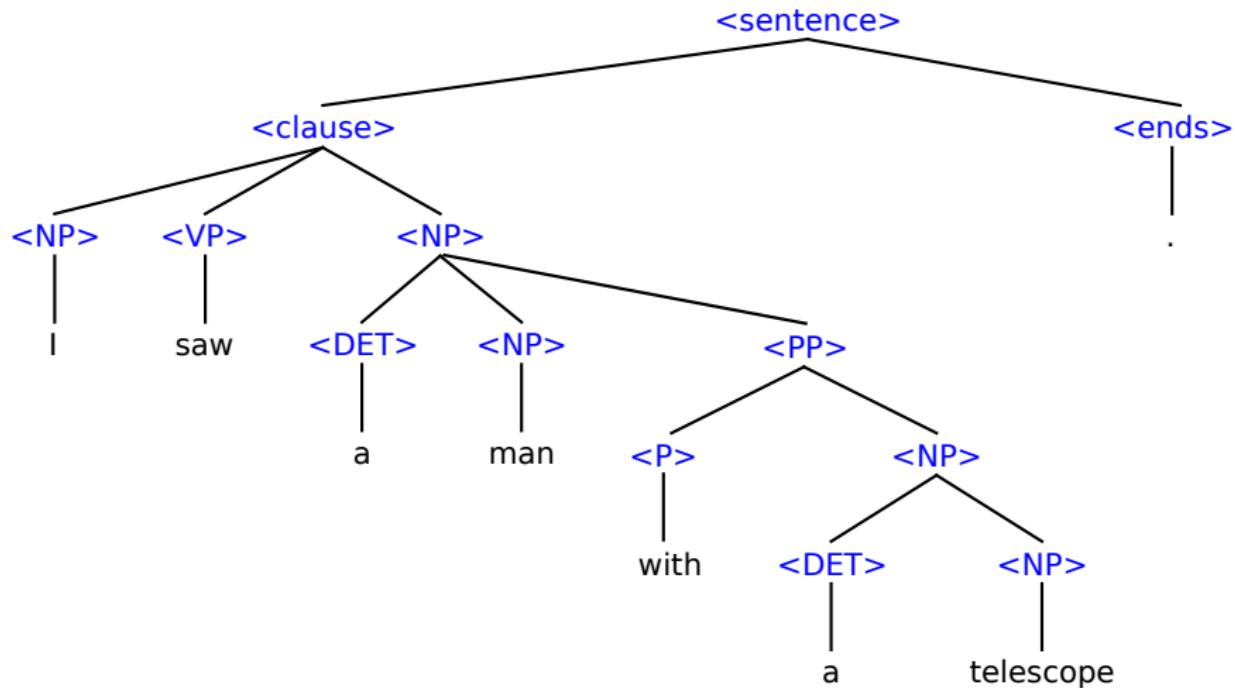
Základní tvar – lemma

- podstatná jména – 1. pád, jednotné číslo
- přídavná jména – 1. pád, jed. č., mužský rod
- slovesa – infinitiv
- ne vždy jednoznačné: milión/milion, myslit/myslet
- různé preference: nejlepší/dobrý, neučit/učit
při vyhledávání na webu chceme něco jiného než lingvisté
- korpus.cz: řešení pomocí dvou atributů: lemma, sublemma

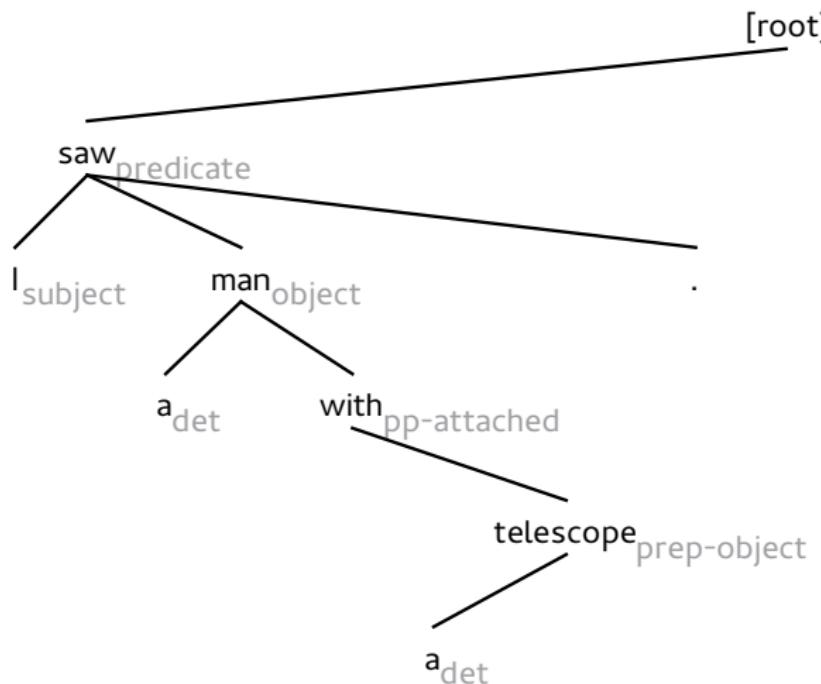
Přístupy k syntaxi

- 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

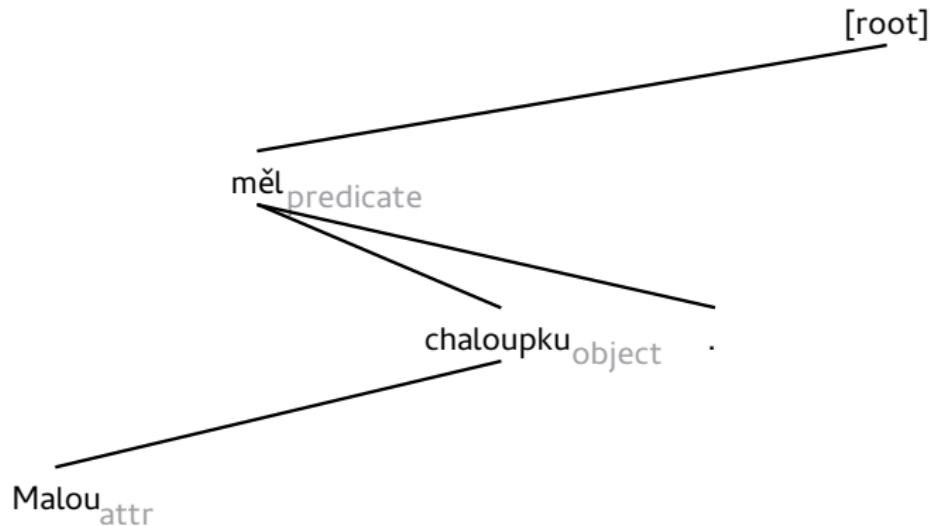
Phrase structure – more fine-grained analysis

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

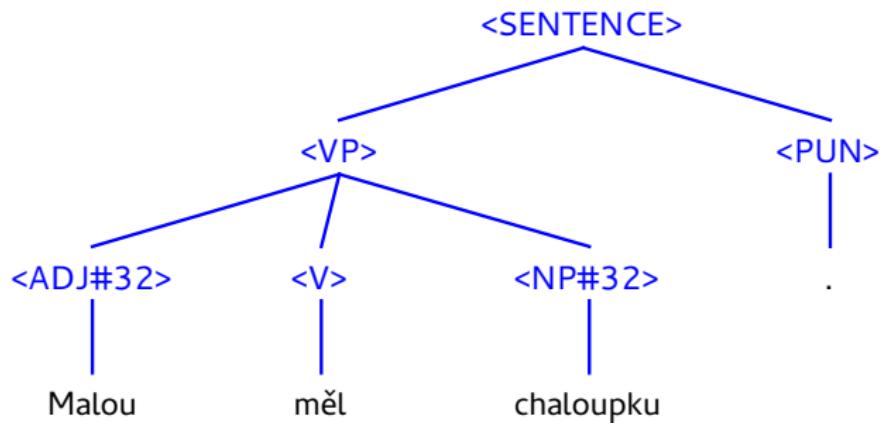
Coordinations and other “flat” phenomena

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

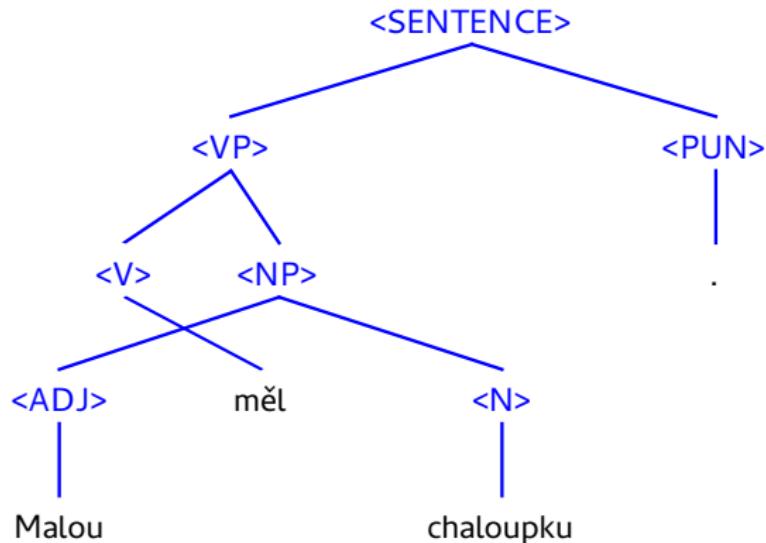
Non-projectivity – example



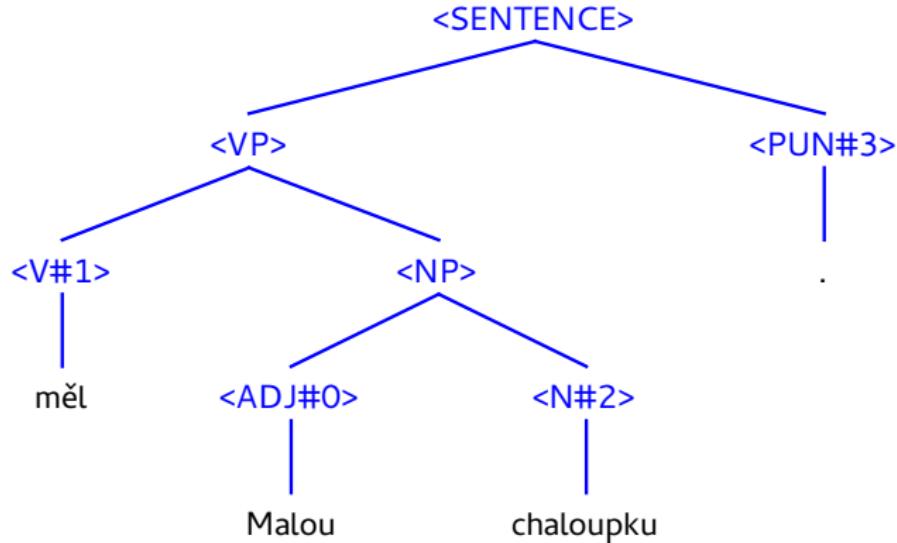
Non-projectivity in phrase structure formalism



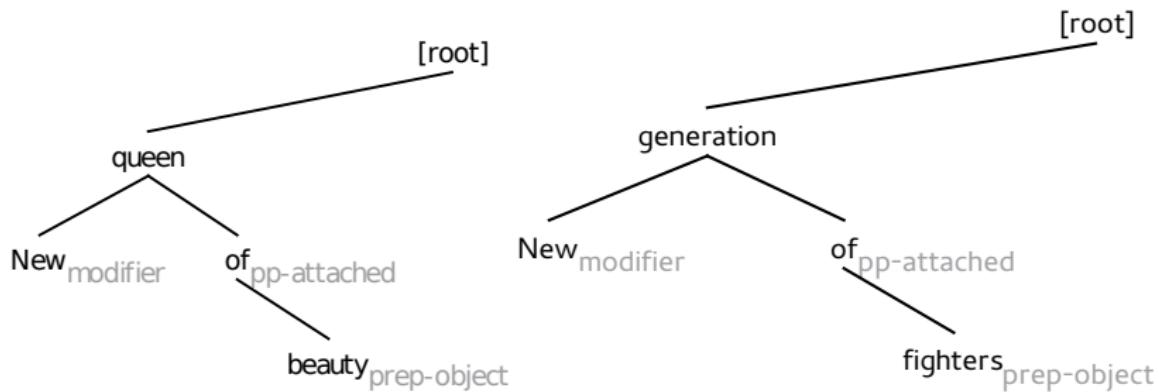
Non-projectivity in phrase structure formalism



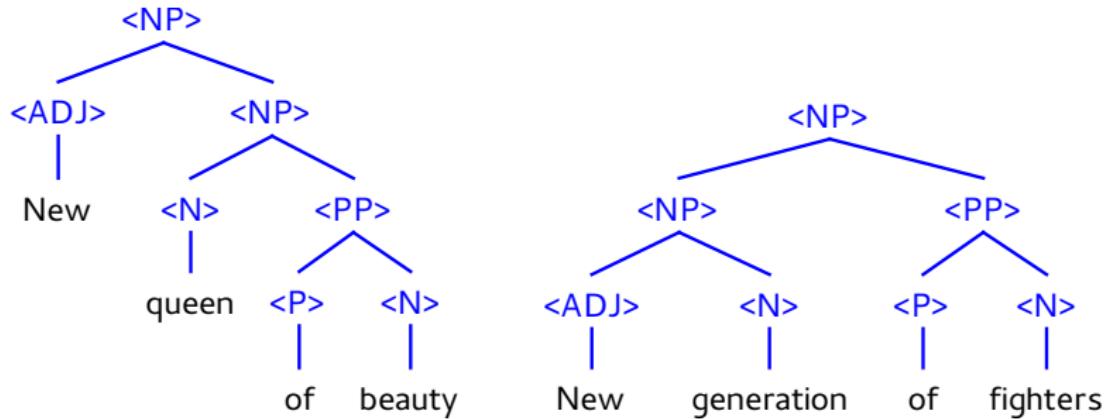
Non-projectivity in phrase structure formalism



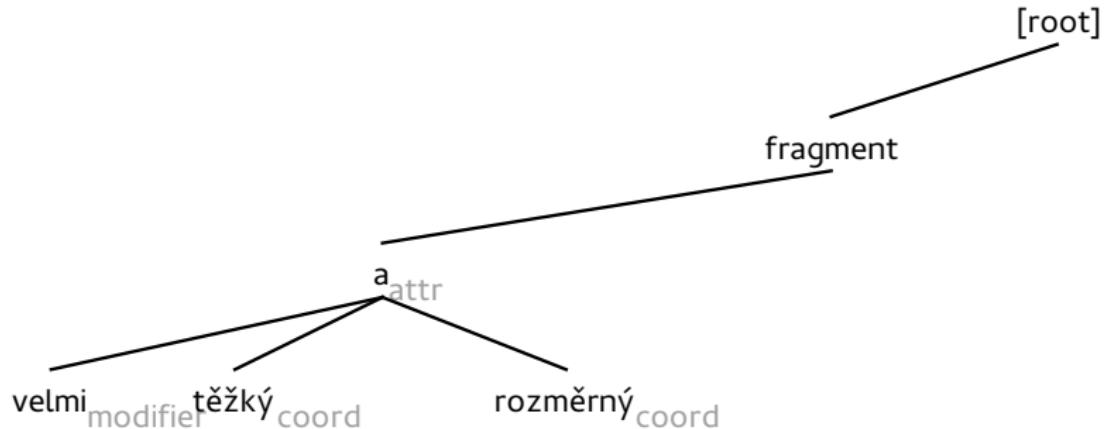
Phrase structure expressivity



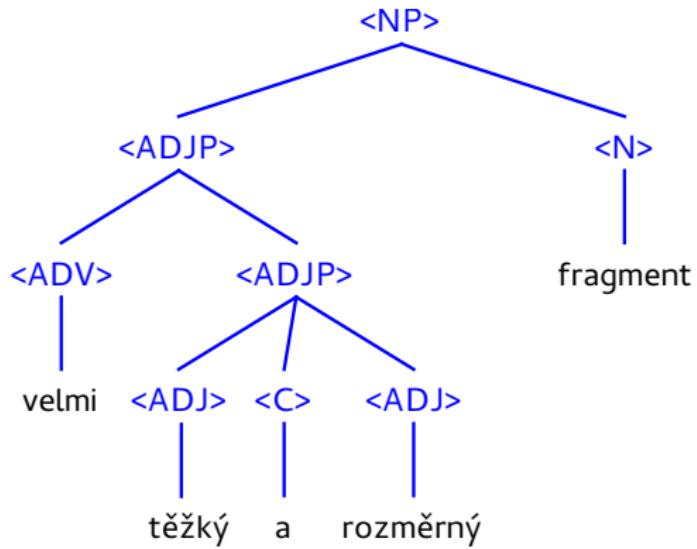
Phrase structure expressivity



Coordinations – dependency structure



Coordinations – phrase structure



Záznam syntaxe v korpusu

- 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	IIb	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]

Záznam syntaxe v korpusu

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
```