

Algoritmy syntaktické analýzy (pomocí CFG)

Vladimír Kadlec, Aleš Horák

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

Obsah:

- ▶ Základní postupy pro syntaktickou analýzu obecných CFG
- ▶ Tomitův zobecněný analyzátor LR
- ▶ Algoritmus CYK
- ▶ Tabulkové analyzátory
- ▶ Porovnání jednotlivých algoritmů
- ▶ Syntaktická analýza s využitím strojového učení

Syntaktická analýza

- ▶ Vstupy:
 - řetězec lexikálních kategorií (preterminálních symbolů) $a_1 \ a_2 \ \dots \ a_n$
např.: ADJ CONJ ADJ N V PREP N '.'
 - bezkontextová gramatika $G = \langle N, \Sigma, P, S \rangle$.
- ▶ Výstup:
 - efektivní reprezentace derivačních stromů.

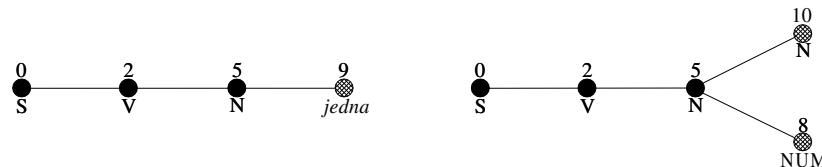
Základní postupy pro syntaktickou analýzu obecných bezkontextových gramatik

- ▶ **obecná CFG** – rozsáhlá, (silně) víceznačná, s ϵ -pravidly
- ▶ všechny uvedené algoritmy pracují s *polynomiální časovou a prostorovou složitostí*
- ▶ **Tomitův zobecněný algoritmus LR (generalized LR)**
- ▶ **algoritmus CYK – Cocke, Younger, Kasami;**
- ▶ **tabulková (chart) analýza (Chart Parsing):**
 - shora dolů (*top-down*);
 - zdola nahoru (*bottom-up*);
 - analýza řízená hlavou pravidla (*head-driven*);

Tomitův zobecněný analyzátor LR

- ▶ **generalized LR parser (GLR)**
- ▶ Masaru Tomita: [Efficient parsing for natural language](#), 1986
- ▶ standardní **LR tabulka**, která může obsahovat **konflikty**;
- ▶ zásobník je reprezentován **acyklickým orientovaným grafem (DAG)**
- ▶ derivační stromy jsou uloženy ve **sbaleném "lese" stromů**
- ▶ v podstatě stejný jako algoritmus LR
- ▶ udržujeme si **seznam aktivních uzlů** zásobníku (grafu)
- ▶ akce **redukce** provádíme vždy před akcemi čtení
- ▶ akci **čtení** provádíme pro všechny aktivní uzly najednou
- ▶ kde je to možné, tam uzly **slučujeme**

Příklad konfliktu redukce/redukce



stav	položka	akce	symbol	další stav
5	$CLAUSE \rightarrow V N \cdot NUM$	shift	NUM	8
	$NN \rightarrow N \cdot N$		N	10
	$NUM \rightarrow \cdot jedna$		jedna	9
	$N \rightarrow \cdot tramvaj$		tramvaj	7
	$N \rightarrow \cdot jedna$			
9	$NUM \rightarrow jedna \cdot$	reduce (6)		
	$N \rightarrow jedna \cdot$	reduce (5)		

Algoritmus CYK

- Gramatika musí být v Chomského normální formě

CNF:
 $A \rightarrow BC$
 $D \rightarrow 'd'$

- Převod libovolné CFG do CNF:

- přidáme nový kořen S_0 : $S_0 \rightarrow S$
- eliminujeme ϵ -pravidla:

$$\begin{array}{l} S \rightarrow Ab \mid B \\ A \rightarrow a \mid \epsilon \end{array} \rightarrow \begin{array}{l} S \rightarrow Ab \mid b \mid B \\ A \rightarrow a \end{array}$$

- eliminujeme jednoduchá pravidla:

$$\begin{array}{l} A \rightarrow B \\ B \rightarrow a \mid CD \end{array} \rightarrow \begin{array}{l} A \rightarrow a \mid CD \\ B \rightarrow a \mid CD \end{array}$$

- rozgenerujeme dlouhá pravidla:

$$\begin{array}{l} A \rightarrow BCD \\ A_1 \rightarrow CD \end{array} \rightarrow \begin{array}{l} A \rightarrow BA_1 \\ A_1 \rightarrow CD \end{array}$$

Algoritmus CYK, příklad – zadání

- vstupní gramatika je:

$$S \rightarrow AA \mid BB \mid AX \mid BY \mid a \mid b$$

$$X \rightarrow SA$$

$$Y \rightarrow SB$$

$$A \rightarrow a$$

$$B \rightarrow b$$

- vstupní řetězec je $w = abaaba$.

Algoritmus CYK, příklad – řešení (matice V)

$$\begin{array}{l} S \rightarrow AA \mid BB \mid AX \mid BY \mid a \mid b \\ X \rightarrow SA \\ Y \rightarrow SB \\ A \rightarrow a \\ B \rightarrow b \end{array}$$

a b a a b a

p – pozice, q – délka

$p \backslash q$	1	2	3	4	5	6
1	S, A	S, B	S, A	S, A	S, B	S, A
2	Y	X	S, X	Y	X	
3	S	\emptyset	Y	S		
4	X	S	\emptyset			
5	\emptyset	X				
6	S					

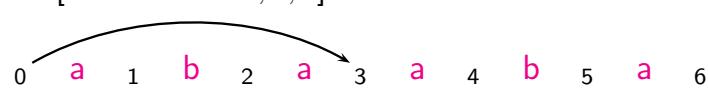
Algoritmus CYK pokrač.

- ▶ Gramatika musí být v Chomského normální formě.
- ▶ Pro daný vstup délky n derivujeme podřetězce symbolů délky q na pozici p , značíme $w_{p,q}$, $1 \leq p, q \leq n$.
- ▶ Derivace řetězců délky 1, $A \Rightarrow w_{p,1}$, je prováděno prohledáváním terminálních pravidel.
- ▶ Derivace delších řetězců $A \Rightarrow^* w_{p,q}$, $q \geq 2$ vyžaduje aby platilo $A \Rightarrow BC \Rightarrow^* w_{p,q}$. Tedy z B derivujeme řetězec délky k , $1 \leq k \leq q$, a z C derivujeme zbytek, řetězec délky $q - k$. Tzn. $B \Rightarrow^* w_{p,k}$ a $C \Rightarrow^* w_{p+k,q-k}$. Kratší řetězce máme tedy vždy "předpočítané."

Tabulkové (chart) analyzátoře

- ▶ Rozlišujeme tři základní typy tabulkových analyzátorů:
 - shora dolů;
 - zdola nahoru;
 - analýza řízená hlavou pravidla.
- ▶ Mnoho dalších variant je popsáno v:
Sikkel Klaas: *Parsing Schemata: A Framework for Specification and Analysis of Parsing Algorithm*, 1997.
- ▶ Neklade se žádné omezení na gramatiku.
- ▶ Analyzátoři typu "chart" v sobě většinou obsahují dvě datové struktury **chart** a **agendu**. Chart a agenda obsahují tzv. **hrany**.
- ▶ **Hrana** je trojice $[A \rightarrow \alpha\beta, i, j]$, kde:
 - i, j jsou celá čísla, $0 \leq i \leq j \leq n$ pro n slov ve vstupní větě
 - $A \rightarrow \alpha\beta$ je pravidlem vstupní gramatiky.

$[A \rightarrow BC \bullet DE, 0, 3]$



Algoritmus CYK pokrač.

```
program CYK Parser;
begin
  for  $p := 1$  to  $n$  do  $V[p, 1] := \{A | A \rightarrow a_p \in P\}$ ;
  for  $q := 2$  to  $n$  do
    for  $p := 1$  to  $n - q + 1$  do
       $V[p, q] = \emptyset$ ;
      for  $k := 1$  to  $q - 1$  do
         $V[p, q] = V[p, q] \cup \{A | A \rightarrow BC \in P, B \in V[p, k], C \in V[p+k, q-k]\}$ ;
      od
    od
  od
end
```

složitost CYK je $O(n^3)$

Obecný analyzátor typu "chart"

```
program Chart Parser;
begin
  inicializuj (CHART);
  inicializuj (AGENDA);
  while (AGENDA ≠ ∅) do
     $E :=$  vezmi hranu z AGENDA;
    for each (hrana  $F$ , která může být vytvořena pomocí
      hrany  $E$  a nějaké jiné hrany z CHART) do
        if  $F \notin$  AGENDA and  $F \notin$  CHART and  $F \neq E$ 
          then přidej  $F$  do AGENDA;
        fi;
    od;
    přidej  $E$  do CHART;
  od;
end;
```

složitost tabulkové analýzy je $O(n^3)$ ($|Pravidla|$ bereme jako konstantu)

Varianta shora dolů

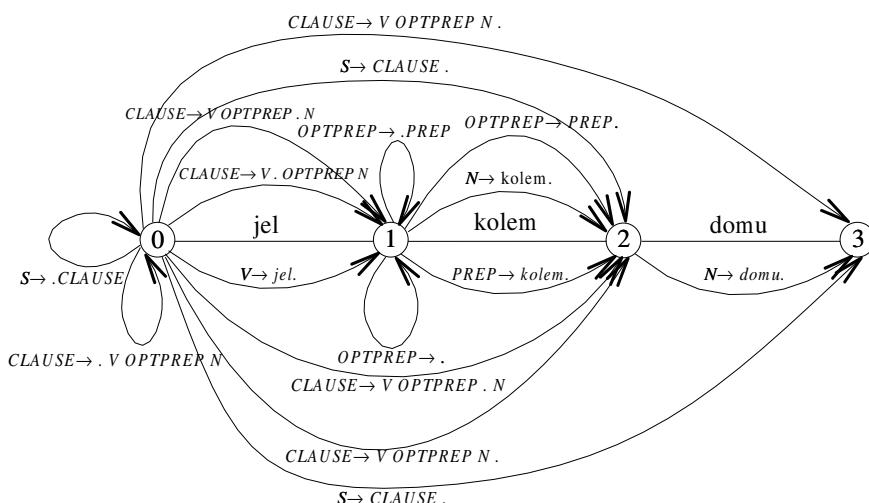
Inicializace:

- $\forall p \in P \mid p = S \rightarrow \alpha$ přidej hranu $[S \rightarrow \bullet\alpha, 0, 0]$ do agendy.
- počáteční chart je prázdný.

Iterace – vezmi hranu E z agendy a pak:

- (fundamentální pravidlo) pokud je E ve tvaru $[A \rightarrow \alpha_0, j, k]$, potom pro každou hranu $[B \rightarrow \gamma \bullet A \beta, i, j]$ v chartu vytvoř hranu $[B \rightarrow \gamma A \bullet \beta, i, k]$.
- (uzavřené hrany) pokud je E ve tvaru $[B \rightarrow \gamma \bullet A \beta, i, j]$, potom pro každou hranu $[A \rightarrow \alpha_0, j, k]$ v chartu vytvoř hranu $[B \rightarrow \gamma A \bullet \beta, i, k]$.
- (terminál na vstupu) pokud je E ve tvaru $[A \rightarrow \alpha_0 \bullet a_{j+1} \beta, i, j]$, vytvoř hranu $[A \rightarrow \alpha a_{j+1} \bullet \beta, i, j+1]$.
- (predikce) pokud je E ve tvaru $[A \rightarrow \alpha_0 B \beta, i, j]$ potom pro každé pravidlo $B \rightarrow \gamma \in P$, vytvoř hranu $[B \rightarrow \bullet \gamma, j, j]$.

Příklad – chart po analýze shora dolů



Příklad – tabulkové analýzy (typu chart)

Gramatika:

S	\rightarrow	$CLAUSE$
$CLAUSE$	\rightarrow	$V OPTPREP N$
$OPTPREP$	\rightarrow	ϵ
$OPTPREP$	\rightarrow	$PREP$
V	\rightarrow	jel
$PREP$	\rightarrow	$kolem$
N	\rightarrow	$domu$
N	\rightarrow	$kolem$

Věta:

"jel kolem domu" ($a_1=jel$, $a_2=kolem$, $a_3=domu$).

Varianta zdola nahoru

Inicializace:

- $\forall p \in P \mid p = A \rightarrow \epsilon$ přidej hrany $[A \rightarrow \bullet, 0, 0]$, $[A \rightarrow \bullet, 1, 1]$, ..., $[A \rightarrow \bullet, n, n]$ do agendy.
- $\forall p \in P \mid p = A \rightarrow a_i \alpha$ přidej hranu $[A \rightarrow \bullet a_i \alpha, i-1, i-1]$ do agendy.
- počáteční chart je prázdný.

Iterace – vezmi hranu E z agendy a pak:

- (fundamentální pravidlo) pokud je E ve tvaru $[A \rightarrow \alpha_0, j, k]$, potom pro každou hranu $[B \rightarrow \gamma \bullet A \beta, i, j]$ v chartu vytvoř hranu $[B \rightarrow \gamma A \bullet \beta, i, k]$.
- (uzavřené hrany) pokud je E ve tvaru $[B \rightarrow \gamma \bullet A \beta, i, j]$, potom pro každou hranu $[A \rightarrow \alpha_0, j, k]$ v chartu vytvoř hranu $[B \rightarrow \gamma A \bullet \beta, i, k]$.
- (terminál na vstupu) pokud je E ve tvaru $[A \rightarrow \alpha_0 \bullet a_{j+1} \beta, i, j]$, potom vytvoř hranu $[A \rightarrow \alpha a_{j+1} \bullet \beta, i, j+1]$.
- (predikce) pokud je E ve tvaru $[A \rightarrow \alpha_0, i, j]$, potom pro každé pravidlo $B \rightarrow A \gamma$ vstupní gramatiky vytvoř hranu $[B \rightarrow \bullet A \gamma, i, i]$.

Analýza řízená hlavou pravidla

- ▶ head-driven chart parsing
- ▶ Hlava pravidla – libovolný (určený) symbol z pravé strany pravidla.
Například pravidlo $CLAUSE \rightarrow V \text{ } PREP \text{ } N$ může mít hlavy $V, PREP, N$.
- ▶ Epsilon pravidlo má hlavu ϵ .
- ▶ Hrana v analyzátoru řízeném hlavou pravidla – trojice $[A \rightarrow \alpha \cdot \beta \cdot \gamma, i, j]$, kde i, j jsou celá čísla, $0 \leq i \leq j \leq n$ pro n slov ve vstupní větě a $A \rightarrow \alpha \beta \gamma$ je pravidlo vstupní gramatiky a hlava je v β .
- ▶ Algoritmus vlastní analýzy (varianta zdola nahoru) je podobný jednoduchému přístupu. Analýza neprobíhá zleva doprava, ale začíná na hlavě daného pravidla.

Analyzátor řízený hlavou pravidla pokrač.

Iterace – vezmi hranu E z agendy a pak:

- a₁) pokud je E ve tvaru $[A \rightarrow \cdot \alpha \cdot, j, k]$, potom pro každou hranu: $[B \rightarrow \beta \cdot \gamma \cdot A \delta, i, j]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot \gamma A \cdot \delta, i, k]$,
- a₂) pro $[B \rightarrow \beta A \cdot \gamma \cdot \delta, k, l]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot A \gamma \cdot \delta, j, l]$.
- b₁) pokud je E ve tvaru $[B \rightarrow \beta \cdot \gamma \cdot A \delta, i, j]$, potom pro každou hranu $[A \rightarrow \cdot \alpha \cdot, j, k]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot \gamma A \cdot \delta, i, k]$.
- b₂) pokud je E ve tvaru $[B \rightarrow \beta A \cdot \gamma \cdot \delta, k, l]$, potom pro každou hranu $[A \rightarrow \cdot \alpha \cdot, j, k]$ v chartu vytvoř hranu $[B \rightarrow \beta \cdot A \gamma \cdot \delta, j, l]$.
- c₁) pokud je E ve tvaru $[A \rightarrow \beta a_i \cdot \gamma \cdot \delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta \cdot a_i \gamma \cdot \delta, i-1, j]$.
- c₂) pokud je E ve tvaru $[A \rightarrow \beta \cdot \gamma \cdot a_{j+1} \delta, i, j]$, potom vytvoř hranu $[A \rightarrow \beta \cdot \gamma a_{j+1} \cdot \delta, i, j+1]$.
- d) pokud je E ve tvaru $[A \rightarrow \cdot \alpha \cdot, i, j]$, potom pro každé pravidlo $B \rightarrow \beta \underline{A} \gamma$ ve vstupní gramatice vytvoř hranu $[B \rightarrow \beta \cdot A \cdot \gamma, i, j]$ (symbol A je hlavou pravidla).

Analyzátor řízený hlavou pravidla

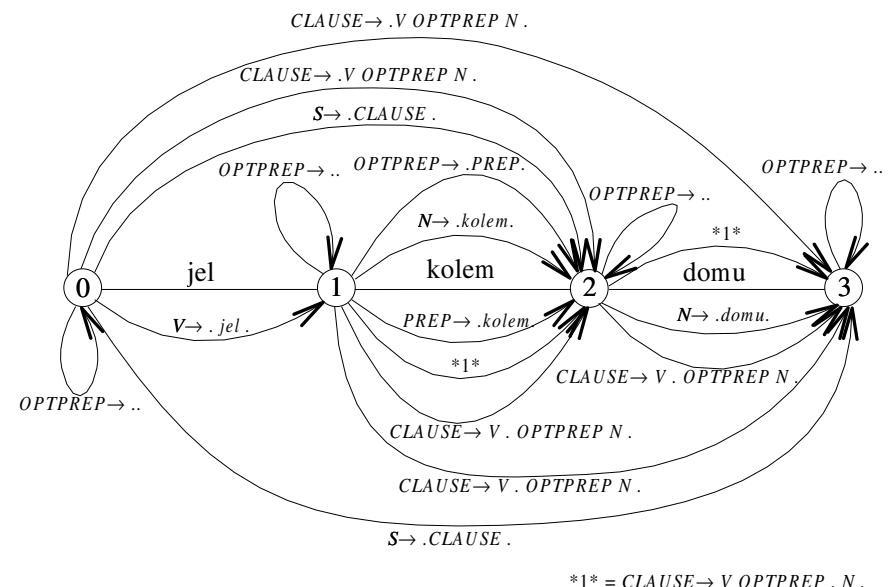
Inicializace:

- ▶ $\forall p \in P \mid p = A \rightarrow \epsilon$ přidej hrany $[A \rightarrow \cdot \cdot \cdot, 0, 0], [A \rightarrow \cdot \cdot \cdot, 1, 1], \dots, [A \rightarrow \cdot \cdot \cdot, n, n]$ do agendy.
- ▶ $\forall p \in P \mid p = A \rightarrow \alpha a_i \beta$ (a_i je hlavou pravidla) přidej hranu $[A \rightarrow \alpha \cdot a_i \beta, i-1, i]$ do agendy.
- ▶ počáteční chart je prázdný.

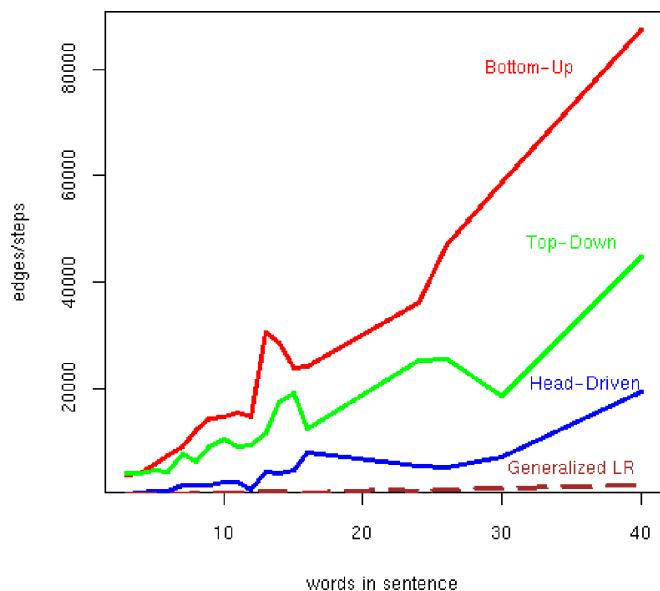
Je tato inicializace v pořádku?

Co když inicializace nic nepřidá? (žadné ϵ ani žádný terminál jako hlava)
Odpověď: taková gramatika by generovala prázdný jazyk.

Příklad – chart po analýze řízené hlavou pravidla

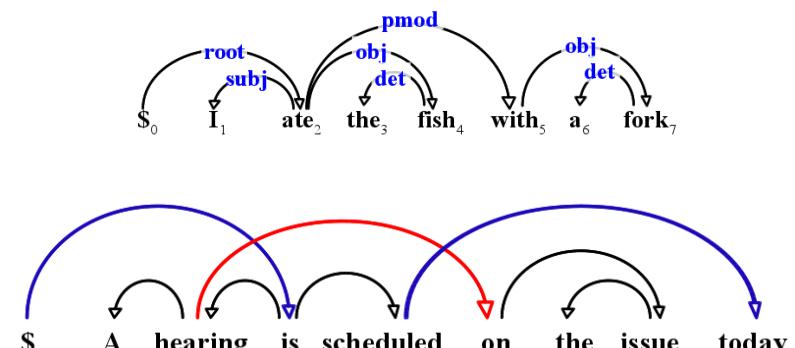


Porovnání jednotlivých algoritmů



Syntaktická analýza s využitím strojového učení

- nejčastěji pro **závislostní formalismy**
- **jedna hrana** pro každé slovo
- složitější pro **neprojektivní stromy**

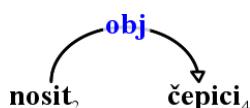


Example from "Dependency Parsing" by Kübler, Nivre, and McDonald, 2009

Hodnocení úspěšnosti

základní informace:

- **hlava** – které slovo je řídící
- **potomek** – které slovo je **závislé**
- **typ** – označení **typu hrany (label)**



metriky (vždy procentuálně):

- **Unlabeled attachment score (UAS)** – slova, která mají správnou hlavu
- **Labeled attachment score (LAS)** – slova, která mají správnou hlavu a typ
- **Root Accuracy (RA)** – analýzy, které mají správný kořen
- **Complete Match rate (CM)** – zcela správné analýzy

Formalizace závislostní analýzy pro učení

$$\text{Tree}^{\text{best}} = \arg \max_{\text{Tree} \in \Phi(\text{Sentence})} \text{score}(\text{Sentence}, \text{Tree})$$

- **Sentence** = $x_1 x_2 \dots x_n$ – vstupní věta
- (h, p) – hrana mezi hlavou x_h a potomkem x_p
- $\text{Tree} = \{(h, p) : 0 \leq h \leq n, 0 < p \leq n\}$ – potenciální strom
- $\Phi(\text{Sentence})$ – množina všech možných závislostních stromů nad Sentence
- $\text{score}(\text{Sentence}, \text{Tree})$ – závisí na algoritmu, např.

$$\text{score}(\text{Sentence}, \text{Tree}) = \sum_{(h,p) \in \text{Tree}} \text{score}(\text{Sentence}, h, p)$$

Způsob řešení závislostní analýzy

základní přístupy:

- ▶ řešení pomocí přechodových akcí (*transition-based*) – sekvence akcí přiřazujících závislostní hrany, využívá zásobník *arc-standard* akce – `shift`, `leftarc_type`, `rightarc_type`
takto odpovídá shift-reduce analýze, s dalšími akcemi (`swap`, `reduce`)
zvládne i neprojektivní analýzy
např. *MaltParser* (Nivre et al, 2006)
- ▶ grafové řešení (*graph-based*) – tvorba stromu z ohodnoceného seznamu hran
grafové řešení je **přesnější** na delších větách, klade ale větší **požadavky** na vlastnosti `score()`

Závislostní analýza pomocí přechodových akcí – příklad

krok	zásobník	vstup	akce	hrana
0	[root]	[dej, Karlovi, tu, novou, knihu]	SHIFT	
1	[root, dej]	[Karlovi, tu, novou, knihu]	SHIFT	
2	[root, dej, Karlovi]	[tu, novou, knihu]	RIGHTARC	(dej → Karlovi)
3	[root, dej]	[tu, novou, knihu]	SHIFT	
4	[root, dej, tu]	[novou, knihu]	SHIFT	
5	[root, dej, tu, novou]	[knihu]	SHIFT	
6	[root, dej, tu, novou, knihu]	[]	LEFTARC	(novou ← knihu)
7	[root, dej, tu, knihu]	[]	LEFTARC	(tu ← knihu)
8	[root, dej, knihu]	[]	RIGHTARC	(dej → knihu)
9	[root, dej]	[]	RIGHTARC	(root → dej)
10	[root]	[]	—	

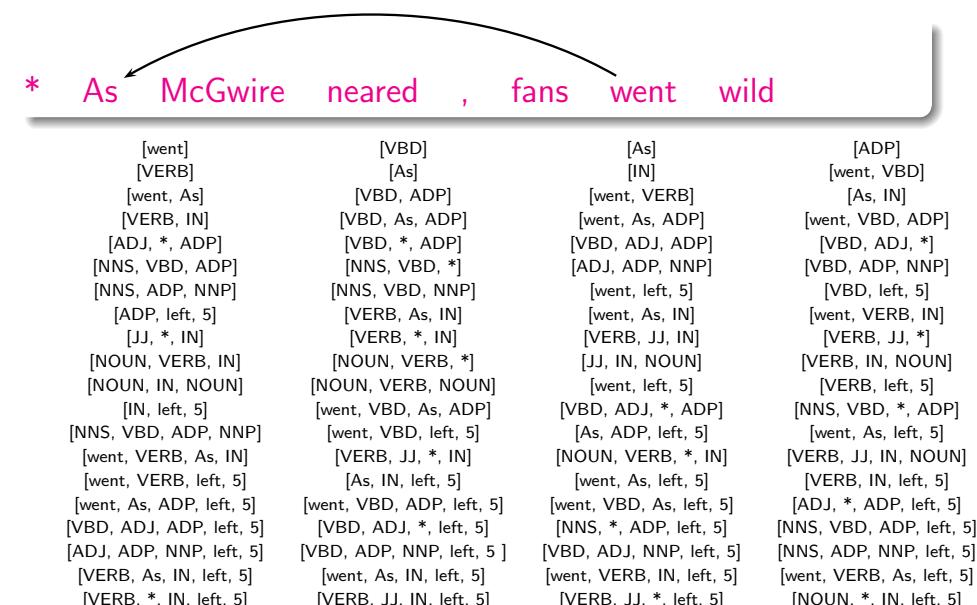
Grafové řešení závislostní analýzy

2 úkoly:

- ▶ nalezení stromu (*search problem*)
 - známe skóre hran, jak najdeme *Tree^{best}*
 - např. *Maximum Spanning Tree* (McDonald et al, 2005)
- ▶ učení (*learning problem*)
 - máme zadané věty a stromy, jak určíme skóre hran
 - pomocí rysů hran a online učení

UDPipe 2 implementuje grafové řešení analýzy

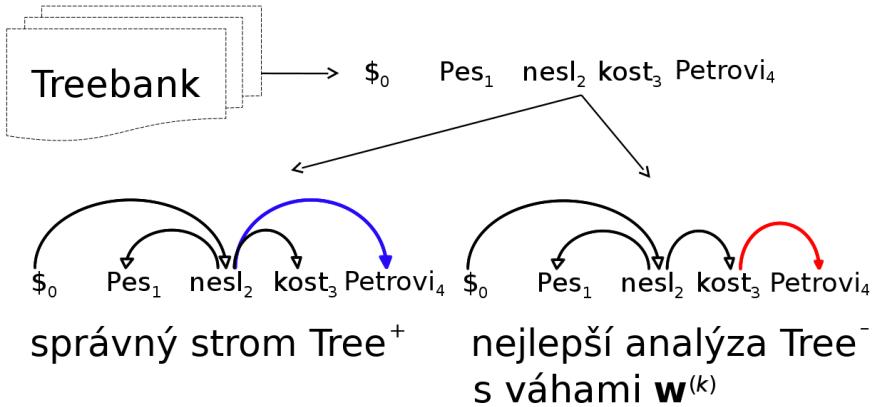
Rysy závislostních hran



(příklad z Rush and Petrov, 2012)

Online učení skóre závislostních hran

učení **vah jednotlivých rysů w**



$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \mathbf{f}(\text{Sentence}, \text{Tree}^+) - \mathbf{f}(\text{Sentence}, \text{Tree}^-)$$