Algoritmy syntaktické analýzy (pomocí CFG)

Vladimír Kadlec, Aleš Horák

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

Obsah:

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*);

Syntaktická analýza

- Vstupy:
  - řetězec lexikálních kategorií (preterminálních symbolů) $a_1\ a_2\ \ldots\ a_n$

    např.: ADJ CONJ ADJ N V PREP N '.'
  - bezkontextová gramatika $G = \langle N, \Sigma, P, S \rangle$.
- Výstup:
  - efektivní reprezentace derivačních stromů.

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

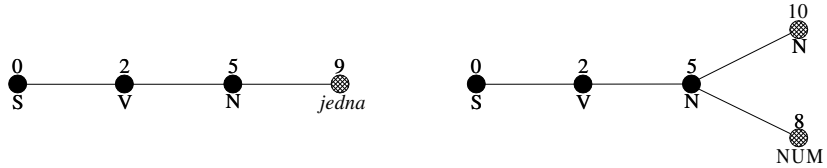

stav	položka	akce	symbol	další stav
5	$CLAUSE \rightarrow V\ N_{\bullet} NUM$	shift	NUM	8
	$NN \rightarrow N_{\bullet} N$		N	10
	$NUM \rightarrow {}_{\bullet} jedna$		$jedna$	9
	$N \rightarrow {}_{\bullet} tramvaj$		$tramvaj$	7
	$N \rightarrow {}_{\bullet} jedna$			
9	$NUM \rightarrow jedna_{\bullet}$	reduce (6)		
	$N \rightarrow jedna_{\bullet}$	reduce (5)		

Algoritmus CYK

- Gramatika musí být v Chomského normální formě

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

- Převod libovolné CFG do CNF:
  1. přidáme nový kořen S_0: $S_0 \rightarrow S$
  2. eliminujeme ϵ-pravidla:

     $S \rightarrow Ab \mid B$, $A \rightarrow a \mid \epsilon$ $\rightarrow$ $S \rightarrow Ab \mid b \mid B$, $A \rightarrow a$
  3. eliminujeme jednoduchá pravidla:

     $A \rightarrow B$, $B \rightarrow a \mid CD$ $\rightarrow$ $A \rightarrow a \mid CD$, $B \rightarrow a \mid CD$
  4. rozgenerujeme dlouhá pravidla:

     $A \rightarrow BCD$ $\rightarrow$ $A \rightarrow BA_1$, $A_1 \rightarrow CD$

Algoritmus CYK, příklad – zadání

- vstupní gramatika je:

  $S \rightarrow AA|BB|AX|BY|a|b$
  $X \rightarrow SA$
  $Y \rightarrow SB$
  $A \rightarrow a$
  $B \rightarrow b$

- vstupní řetězec je $w = abaaba$.

Algoritmus CYK, příklad – řešení (matice V)

a b a a b a

$S \rightarrow AA|BB|AX|BY|a|b$
$X \rightarrow SA$
$Y \rightarrow SB$
$A \rightarrow a$
$B \rightarrow b$

p – pozice, q – délka

q \ p	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."

Algoritmus CYK pokrač.

```
program CYK Parser;
begin
    for p := 1 to n do V[p,1] := {A|A → a_p ∈ P };
    for q := 2 to n do
        for p := 1 to n − q + 1 do
            V[p,q] = ∅;
            for k :=1 to q − 1 do
                V[p,q] =
                    V[p,q] ∪
                    ∪ {A|A → BC ∈ P, B ∈ V[p,k], C ∈ V[p + k, q − k]};
            od
        od
    od
end
```

složitost CYK je $O(n^3)$

Tabulkové (chart) analyzátory

- 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.
- Analyzátory typu "chart" v sobě většinou obsahují dvě datové struktury chart a agendu. Chart a agenda obsahují tzv. *hrany*.
- Hrana je trojice $[A \rightarrow \alpha \bullet \beta, i, j]$, kde:
  - i, j jsou celá čísla, $0 \leq i \leq j \leq n$ pro n slov ve vstupní větě
  - a $A \rightarrow \alpha\beta$ je pravidlem vstupní gramatiky.

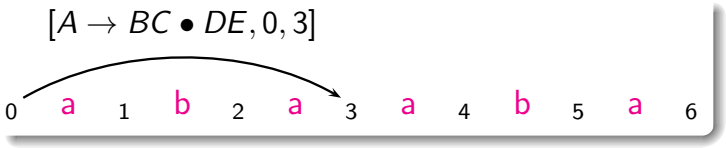

Obecný analyzátor typu "chart"

```
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 ∉ AGENDA and F ∉ CHART and F ≠ 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:

a) (*fundamentální pravidlo*) pokud je E ve tvaru $[A\rightarrow \alpha\bullet,\ j,\ k]$, potom pro každou hranu $[B\rightarrow \gamma\bullet A\,\beta,\ i,\ j]$ v chartu vytvoř hranu $[B\rightarrow \gamma A\bullet\beta,\ i,\ k]$.

b) (*uzavřené hrany*) pokud je E ve tvaru $[B\rightarrow \gamma\bullet A\beta,\ i,\ j]$, potom pro každou hranu $[A\rightarrow \alpha\bullet,\ j,\ k]$ v chartu vytvoř hranu $[B\rightarrow \gamma A\bullet\beta,\ i,\ k]$.

c) (*terminál na vstupu*) pokud je E ve tvaru $[A\rightarrow \alpha\bullet a_{j+1}\beta,\ i,\ j]$, vytvoř hranu $[A\rightarrow \alpha a_{j+1}\bullet\beta,\ i,\ j{+}1]$.

d) (*predikce*) pokud je E ve tvaru $[A\rightarrow \alpha\bullet B\beta,\ i,\ j]$ potom pro každé pravidlo $B \rightarrow \gamma \in P$, vytvoř hranu $[B\rightarrow \bullet\gamma,\ j,\ j]$.

Příklad – tabulkové analýzy (typu chart)

Gramatika:

$$\begin{aligned} S &\rightarrow CLAUSE \\ CLAUSE &\rightarrow V\ OPTPREP\ N \\ OPTPREP &\rightarrow \epsilon \\ OPTPREP &\rightarrow PREP \\ V &\rightarrow jel \\ PREP &\rightarrow kolem \\ N &\rightarrow domu \\ N &\rightarrow kolem \end{aligned}$$

Věta:

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

Příklad – chart po analýze shora dolů

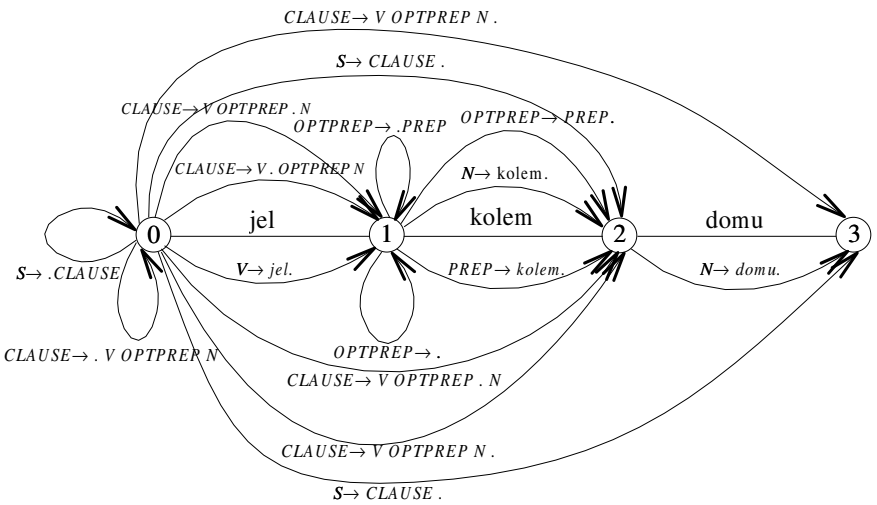

Varianta zdola nahoru

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 $[A\rightarrow \bullet a_i\alpha,\ i\text{-}1,\ i\text{-}1]$ do agendy.
- počáteční chart je prázdný.

Iterace – vezmi hranu E z agendy a pak:

a) (*fundamentální pravidlo*) pokud je E ve tvaru $[A\rightarrow \alpha\bullet,\ j,\ k]$, potom pro každou hranu $[B\rightarrow \gamma\bullet A\beta,\ i,\ j]$ v chartu vytvoř hranu $[B\rightarrow \gamma A\bullet\beta,\ i,\ k]$.

b) (*uzavřené hrany*) pokud je E ve tvaru $[B\rightarrow \gamma\bullet A\beta,\ i,\ j]$, potom pro každou hranu $[A\rightarrow \alpha\bullet,\ j,\ k]$ v chartu vytvoř hranu $[B\rightarrow \gamma A\bullet\beta,\ i,\ k]$.

c) (*terminál na vstupu*) pokud je E ve tvaru $[A\rightarrow \alpha\bullet a_{j+1}\beta,\ i,\ j]$, potom vytvoř hranu $[A\rightarrow \alpha a_{j+1}\bullet\beta,\ i,\ j{+}1]$.

d) (*predikce*) pokud je E ve tvaru $[A\rightarrow \alpha\bullet,\ i,\ j]$, 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* → *V* *PREP* *N* může mít hlavy *V*, *PREP*, *N*.
- Epsilon pravidlo má hlavu ϵ.
- Hrana v analyzátoru řízeném hlavou pravidla – trojice $[A \rightarrow \alpha_\bullet\beta_\bullet\gamma,\ i,\ j]$, 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

Inicializace:

- $\forall\ p \in P \mid p = A \rightarrow \epsilon$ přidej hrany $[A \rightarrow \bullet\bullet,\ 0,\ 0]$, $[A \rightarrow \bullet\bullet,\ 1,\ 1]$, ..., $[A \rightarrow \bullet\bullet,\ n,\ n]$ do agendy.
- $\forall\ p \in P \mid p = A \rightarrow \alpha\underline{a_i}\beta$ (a_i je hlavou pravidla) přidej hranu $[A \rightarrow \alpha_\bullet a_i{}_\bullet\beta,\ i\text{-}1,\ i]$ 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.

Analyzátor řízený hlavou pravidla pokrač.

Iterace – vezmi hranu *E* z agendy a pak:

a_1) pokud je E ve tvaru $[A \rightarrow \bullet\alpha_\bullet,\ j,\ k]$, potom pro každou hranu: $[B \rightarrow \beta_\bullet\gamma_\bullet A\delta,\ i,\ j]$ v chartu vytvoř hranu $[B \rightarrow \beta_\bullet\gamma A_\bullet\delta,\ i,\ k]$,

a_2) pro $[B \rightarrow \beta A_\bullet\gamma_\bullet\delta,\ k,\ l]$ v chartu vytvoř hranu $[B \rightarrow \beta_\bullet A\gamma_\bullet\delta,\ j,\ l]$.

b_1) pokud je E ve tvaru $[B \rightarrow \beta_\bullet\gamma_\bullet A\delta,\ i,\ j]$, potom pro každou hranu $[A \rightarrow \bullet\alpha_\bullet,\ j,\ k]$ v chartu vytvoř hranu $[B \rightarrow \beta_\bullet\gamma A_\bullet\delta,\ i,\ k]$.

b_2) pokud je E ve tvaru $[B \rightarrow \beta A_\bullet\gamma_\bullet\delta,\ k,\ l]$, potom pro každou hranu $[A \rightarrow \bullet\alpha_\bullet,\ j,\ k]$ v chartu vytvoř hranu $[B \rightarrow \beta_\bullet A\gamma_\bullet\delta,\ j,\ l]$.

c_1) pokud je E ve tvaru $[A \rightarrow \beta a_i{}_\bullet\gamma_\bullet\delta,\ i,\ j]$, potom vytvoř hranu $[A \rightarrow \beta_\bullet a_i\gamma_\bullet\delta,\ i\text{-}1,\ j]$.

c_2) pokud je E ve tvaru $[A \rightarrow \beta_\bullet\gamma_\bullet a_{j+1}\delta,\ i,\ j]$, potom vytvoř hranu $[A \rightarrow \beta_\bullet\gamma a_{j+1}{}_\bullet\delta,\ i,\ j\text{+}1]$.

d) pokud je E ve tvaru $[A \rightarrow \bullet\alpha_\bullet,\ i,\ j]$, potom pro každé pravidlo $B \rightarrow \beta\ \underline{A}\ \gamma$ ve vstupní gramatice vytvoř hranu $[B \rightarrow \beta_\bullet A_\bullet\gamma,\ i,\ j]$ (symbol *A* je hlavou pravidla).

Příklad – chart po analýze řízené hlavou pravidla

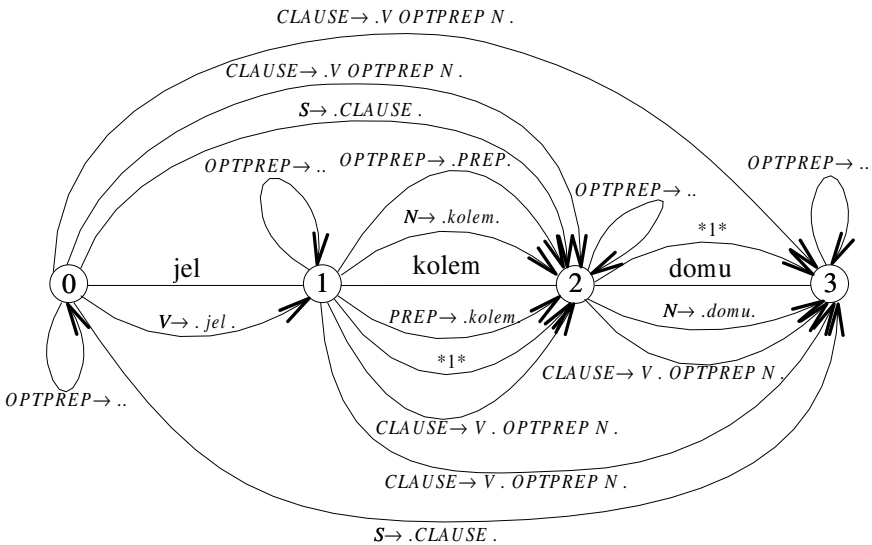

1 = *CLAUSE→ V OPTPREP . N .*

Porovnání jednotlivých algoritmů

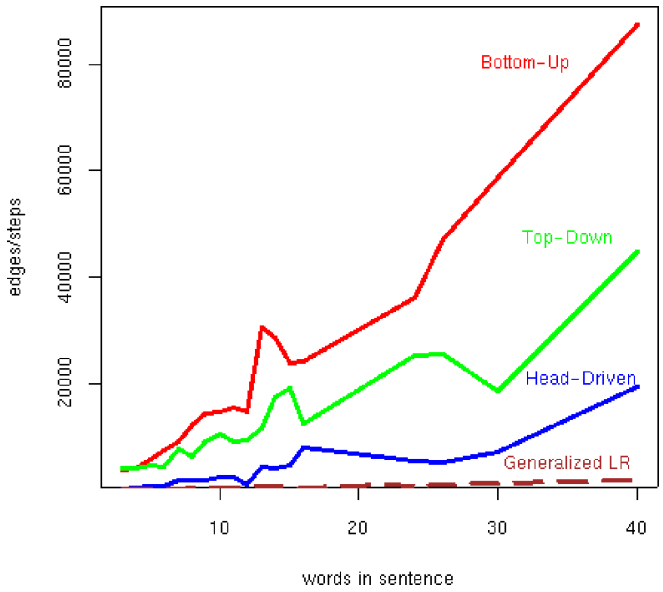

Syntaktická analýza s využitím strojového učení

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

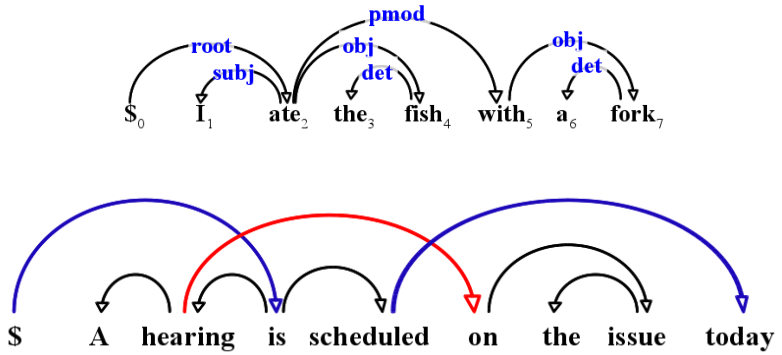

Example from "Dependency Parsing" by Kübler, Nivre, and McDonald, 2009

Hodnocení úspěšnosti

základní informace:

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

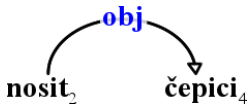

metriky (vždy procentuálně):

- 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

$$Tree^{best} = \underset{Tree \in \Phi(Sentence)}{\arg\max} \; score(Sentence, Tree)$$

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

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

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 flexibilnější

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

Rysy závislostních hran

[went]	[VBD]	[As]	[ADP]
[VERB]	[As]	[IN]	[went, VBD]
[went, As]	[VBD, ADP]	[went, VERB]	[As, IN]
[VERB, IN]	[VBD, As, ADP]	[went, As, ADP]	[went, VBD, ADP]
[ADJ, *, ADP]	[VBD, *, ADP]	[VBD, ADJ, ADP]	[VBD, ADJ, *]
[NNS, VBD, ADP]	[NNS, VBD, *]	[ADJ, ADP, NNP]	[VBD, ADP, NNP]
[NNS, ADP, NNP]	[NNS, VBD, NNP]	[went, left, 5]	[VBD, left, 5]
[ADP, left, 5]	[VERB, As, IN]	[went, As, IN]	[went, VERB, IN]
[JJ, *, IN]	[VERB, *, IN]	[VERB, JJ, IN]	[VERB, JJ, *]
[NOUN, VERB, IN]	[NOUN, VERB, *]	[JJ, IN, NOUN]	[VERB, IN, NOUN]
[NOUN, IN, NOUN]	[NOUN, VERB, NOUN]	[went, left, 5]	[VERB, left, 5]
[IN, left, 5]	[went, VBD, As, ADP]	[VBD, ADJ, *, ADP]	[NNS, VBD, *, ADP]
[NNS, VBD, ADP, NNP]	[went, VBD, left, 5]	[As, ADP, left, 5]	[went, As, left, 5]
[went, VERB, As, IN]	[VERB, JJ, *, IN]	[NOUN, VERB, *, IN]	[VERB, JJ, IN, NOUN]
[went, VERB, left, 5]	[As, IN, left, 5]	[went, As, left, 5]	[VERB, IN, left, 5]
[went, As, ADP, left, 5]	[went, VBD, ADP, left, 5]	[went, VBD, As, left, 5]	[ADJ, *, ADP, left, 5]
[VBD, ADJ, ADP, left, 5]	[VBD, ADJ, *, left, 5]	[NNS, *, ADP, left, 5]	[NNS, VBD, ADP, left, 5]
[ADJ, ADP, NNP, left, 5]	[VBD, ADP, NNP, left, 5]	[VBD, ADJ, NNP, left, 5]	[NNS, ADP, NNP, left, 5]
[VERB, As, IN, left, 5]	[went, As, IN, left, 5]	[went, VERB, IN, left, 5]	[went, VERB, As, left, 5]
[VERB, *, IN, left, 5]	[VERB, JJ, IN, left, 5]	[VERB, JJ, *, left, 5]	[NOUN, *, IN, left, 5]

(příklad z Rush and Petrov, 2012)

Online učení skóre závislostních hran

učení vah jednotlivých rysů w

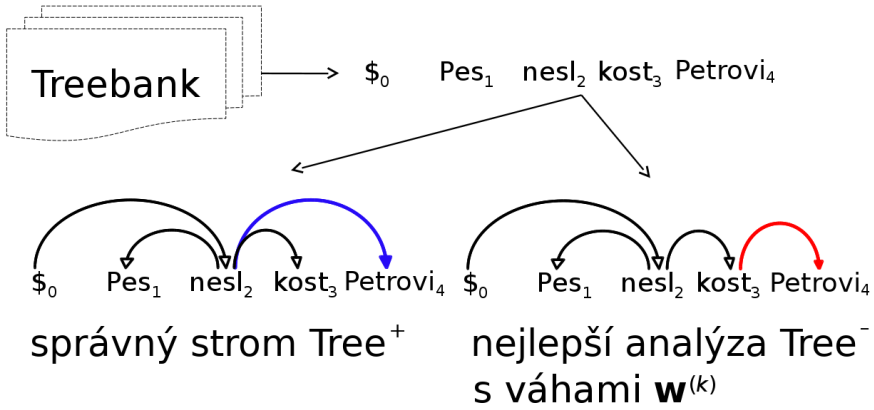

$$w^{(k+1)} = w^{(k)} + f(Sentence, Tree^{+}) - f(Sentence, Tree^{-})$$