

Syntaxe – gramatiky a syntaktické struktury

Aleš Horák

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

Obsah:

- ▶ Syntaxe, syntaktická analýza
- ▶ Základní termíny
- ▶ Specifikace gramatik
- ▶ Chomského teorie syntaxe
- ▶ Východiska syntaktické analýzy

Syntaktická analýza programovacích × přirozených jazyků


- ▶ počítačové programy a přirozené jazyky sdílí **teorii formálních jazyků** a praktický zájem o **efektivní algoritmy** analýzy
- ▶ ALGOL 60 – první programovací jazyk popsaný pomocí **Backus-Naurovy formy (BNF)**

```
<if_statement> ::= if <boolean_expression> then
                  <statement_sequence>
[ else
  <statement_sequence> ]
end if ;
```

- ▶ dokázalo se, že BNF je **ekvivalentní** CFG (1962) → podnítilo výzkum formálních jazyků z hlediska jazyků přirozených

Syntaxe, syntaktická analýza

- ▶ **syntaxe** – charakterizace dobře utvořených kombinací slovních tvarů do **věty** nebo **fráze**
- ▶ pomocí **gramatických pravidel**
- ▶ výstup ze syntaktické analýzy (např. derivační strom) tvoří často **vstup pro analýzu sémantickou**



Typy gramatik

gramatiky:

- ▶ **regulární** (regular) neterminál → **terminál**[neterminál] ekvivalentní síle **konečných automatů**, neumí $a^n b^n$
- ▶ **bezkontextové** (context-free) neterminál → cokoliv ekvivalentní síle **zá sobníkových automatů**, umí $a^n b^n$, neumí $a^n b^n c^n$
- ▶ **kontextové** (context-sensitive) – více termů na levé straně (*kontext neterminálu*) umí $a^n b^n c^n$
- ▶ **rekurzivně vyčíslitelné** (recursively enumerable) – bez omezení ekvivalentní síle **Turingova stroje**
přirozený jazyk byl dlouho pokládán za bezkontextový → nyní prokázáno, že obsahuje **kontextové prvky**

Gramatiky přirozeného jazyka

- konkrétní popis **gramatiky přirozeného jazyka** je velmi složitým úkolem
- kontrast s faktom, že rodilí mluvčí nemívají potíže s pochopením významu vět
- asi **nejstarší formální popis jazyka** – gramatika sanskrtu od indického učence Paniniho



संस्कृत भारती

- vznikla cca 400 př.n.l.
- dochovaná v rituálních védických textech
- gramatika podobná BNF (Backus-Naurově formě)
- používala bezkontextových i kontextových pravidel, obsahovala asi 1700 termů
- zabývala se z větší části morfologií, nikoliv syntaxí, neboť pořádek slov je v sanskrtu dosti volný
- toto dílo bylo evropské škole obecné lingvistiky, která má kořeny v řecké a římské tradici, neznámé až do 19. století

Základní termíny – pokrač.

► frázová kategorie (*phrasal category*)

neterminální symbol gramatiky, který nevyjadřuje lexikální kategorii

- | | | | |
|------|---|------|-----|
| ADJP | → | ADJP | ADJ |
| NP | → | ADJP | N |
| VP | → | V | NP |
| S | → | NP | VP |

► větný člen (*constituent*) lexikální nebo frázová kategorie

Základní termíny

- fráze** (*phrase*) – jednotka jazyka větší než slovo, ale menší než věta např. *jmenná fráze*, *slovesná fráze*, *adjektivní fráze* nebo *příslovečná fráze*
- lexikální symbol, lexikální kategorie** (*lexical category*) tzv. **pre-terminál** speciální neterminál gramatiky, který se přímo přepisuje na terminálový řetězec znaků, tj. pravidla tvaru $X \rightarrow w$

N	→	pes		člověk		dům	...
V	→	nese		chodit		psal	...
ADJ	→	...					
PREP	→	...					
ADV	→	...					

označuje všechny slova, která odpovídají určitému lexikálnímu symbolu (všechna podstatná jména, přídavná jména, ...)


Základní termíny – pokrač.

► větná struktura (*sentence structure*) – strukturovaný popis větných členů

► povrchová struktura (*surface structure*)


derivační/složkový strom

jako výsledek bezkontextové (CF) analýzy



► závislostní struktura (*dependency structure*)

zobrazuje závislosti mezi větnými členy



► hloubková struktura (*deep structure*) – sémantická interpretace fráze.

Popisuje **role větných členů** (agens, patiens, donor, cause, ...)

Složkový a závislostní přístup

dva základní způsoby zadávání gramatik

složkový přístup:

- ▶ skupiny slov tvoří větné jednotky, které jsou označovány jako **fráze**, a jako **větné členy** (*složky, constituents*) formují **větu**
 - ▶ např.
 - podstatné jméno – součást jmenné fráze (noun phrase – NP)
 - jmenná fráze spolu s předložkou – tvoří předložkovou frázi (prepositional phrase – PP)
 - ▶ syntaktická struktura věty je zachycována jako **složkový strom**

Složkový a závislostní přístup – pokrač.

závislostní přístup:


- ▶ jeden člen vazby je označován jako **řídící**, druhý jako **závislý**
 - ▶ např.
přídavné jméno závisí na řídícím podstatném jménu
 - ▶ syntaktická struktura věty je zachycována pomocí **závislostního stromu**:
 - *uzly* odpovídají elementárním jednotkám vstupu (často slovům)
 - *hrany* označují vztahy závislosti mezi elementárními jednotkami
 - ▶ závislost není relací mezi jednotlivými slovy, ale obecně relací mezi jedním **slovem** a **frází** řízenou druhým slovem, např.

vazba mezi konkrétním slovesem a podmětem nebo vazba mezi slovesem a předmětem věty

technicky vzato, závislostní relace je vztahem mezi uzly a podstromy (uzlem a všemi uzly, které na tomto uzlu závisí)

Složkový a závislostní přístup – složkové stromy


Velmi velký a těžký slon nastoupil na palubu číslo 12-386-10, kterou tím zatížil na maximum.



Úvod do počítačové jazykistiky 5/1

Složkový a závislostní přístup – závislostní stromy

Velmi velký a těžký slon nastoupil na palubu číslo 12-386-10, kterou tím zatížil na maximum.




Složkový a závislostní přístup – pokrač.

- jen zřídka se používá **čistě** složkový či striktně závislostní přístup
- ve složkovém jsou závislosti zpravidla vyjádřeny přidáním označení, která složka je řídící pro danou frázi
- závislostní strom bývá doplněn o informaci určující lineární precedenci
- je možné pak mezi těmito přístupy výsledek převádět

Složkový a závislostní přístup – hybridní stromy


Velmi velký a těžký slon nastoupil na palubu číslo 12-386-10, kterou tím zatížil na maximum.



Uzly syntaktického stromu

označení uzlu (název neterminálu) podle zvoleného přístupu reprezentuje:

- gramatická role** (gramatická funkce)
 - charakterizují vztahy mezi větnými složkami na povrchové úrovni
 - určujeme, zda daný větný člen je NP v roli **podmětu**, NP v roli **předmětu**, ADVP určující **lokaci** atd.
 - v češtině (a jazycích se systémem gramatických pádů) pomáhá k určení gramatické role právě **informace o pádu**
 - ovšem přiřazení gramatických rolí ke gramatickým pádům a naopak není zdaleka jednoznačné.




Uzly syntaktického stromu – pokrač.

► tematická role (též hloubkový/sémantický pád)

- na rozdíl od gramatické role se jedná o **sémantickou kategorii**
- určujeme např.:
 - Agens – kdo je životným *původcem* nějaké cílevědomé činnosti
 - Patiens – co hraje roli entity, na kterou *se působí*
 - Donor – osoba, která *dává*
 - Cause – entita, která *způsobuje*, že je něco děláno

Hospodářský vývoj v ČR by mohl být příznivější při pružnější dopravě, v čemž brání některá legislativní opatření.



Příznaky a příznakové struktury

informace v uzlu syntaktického stromu:

- **příznaky/rysy** (*features*) – zaznamenávají **syntaktické nebo sémantické informace** o slovu nebo frázi.

např. **test na shodu**:

Malý Petr přišel domů.

podmět (Petr) je ve shodě s přísudkem (přišel) v **čísle a rodě**
přídavné jméno (malý) a podstatné jméno (Petr) se shodují v **pádě, čísle a rodě**

$$\begin{array}{lcl} S(n, g) & \rightarrow & NP(-, n, g) \quad VP(n, g) \\ NP(c, n, g) & \rightarrow & ADJ(c, n, g) \quad N(c, n, g) \end{array}$$

Pořádek slov ve větě

syntaktická pozice – standardní pozice větných členů ve větě

angličtina: S V O M P T
Subject, Verb, Object, Modus, Place, Temp

- avšak např. předmět se může přesunout na první pozici – **topikalizace**
The book I read.
- v češtině – téměř libovolné přesuny syntaktických elementů souvisí s tzv. **aktuálním větným členěním**

Příznaky a příznakové struktury – pokrač.

- gramatické znaky (slovní druh, gramatický pád, rod, číslo, osoba, ...) je výhodné začlenit do gramatiky ve formě dvojic **atribut–hodnota**
- potom je možné **zobecňovat**, např. vyjádřit shodu v pádě, čísle a rodě výhradně pomocí atributů
- aplikace – v mnoha gramatických formalismech jazykové objekty jsou zde modelovány jako **příznakové struktury** (*feature structures*), tedy právě **matici** dvojic atribut–hodnota.
- u složitějších struktur – nestačí pak běžné porovnání instanciace jde oběma směry → použije se **unifikace**

Možnosti zadávání gramatik

- nejčastější formát specifikace gramatik – **produkční pravidla** gramatika se skládá z pravidel generujících **správně utvořené řetězce**
- cíl analyzátoru – najít odvození vstupního řetězce ze zadaného neterminálu (označovaného obyčejně velkým písmenem *S* z anglického *sentence* – věta) na základě daných pravidel
- pokud je tohoto cíle dosaženo, vstup je akceptován a je mu přiřazena odpovídající struktura
- v minulosti rovněž populární – **přechodové sítě** (*transition networks*) přechody sítě = lingvistické jednotky, uzly sítě = stavы analyzátoru v procesu analýzy vstupu. Přechody jsou označeny symboly definujícími, za jakých podmínek se analyzátor může přesunout z jednoho stavu do stavu druhého.
- **rozšířené přechodové sítě** (*ATN – Augmented TN*) jsou doplněny o podmínky a procedury – ekvivalentní deklarativním gramatikám

Standardní teorie syntaxe

- ▶ 50. léta 20. stol. – **Noam Chomsky** vytvořil **formální teorii syntaxe**
- ▶ jedna ze základních tezí – **autonomie syntaxe**
⇐ k ověření **syntaktické správnosti** věty nepotřebujeme znát její význam

Bezbarvé zelené myšlenky zuřivě spí.
vs.

Spí myšlenky zelené zuřivě bezbarvé.

resp. v angličtině

Colorless green ideas sleep furiously.
vs.

Furiously sleep ideas green colorless.

- ▶ syntaktické principy mají **univerzální platnost** pro různé přirozené jazyky

Chomského standardní teorie syntaxe

znalost jazyka = gramatika

Chomského předpoklady o **rozumu**:

- ▶ rozum má *vrozenou strukturu*
- ▶ rozum je *modulární*
- ▶ rozum obsahuje speciální modul pro *jazyk*
porozumění jazyku je oddělitelné od jiných aktivit
- ▶ syntaxe je *formální*
nezávislá na významu a komunikačních funkcích
- ▶ znanost jazyka je *modulární*
obsahuje moduly pro jednotlivé fáze analýzy jazyka

Standardní teorie syntaxe – pokrač.

- ▶ Noam Chomsky, **Aspects of the Theory of Syntax**, 1965 – standardní teorie syntaxe – **transformační generativní gramatika** (TGG)
- ▶ snaží se řešit i zachycení sémantických vztahů v **hloubkové struktuře**
- ▶ postupně se vyvinula:
 - v **rozšířenou standardní teorii** (1968)
 - později tzv. **Government & Binding Theory** (teorie nadřazení a vazání, 1981), která zakladá na pojmu *univerzální gramatiky*
 - 90. léta – teorie **minimalismu** (snaha po úspornosti popisného aparátu)

Standardní teorie syntaxe – pokrač.

základní části standardní teorie:

▶ bázová komponenta

- ▶ bezkontextová **pravidla** a schémata pravidel generují základní strukturu větných členů
- ▶ **lexikon** popisuje lexikální kategorie a syntaktické rysy lexikálních položek
- ▶ **transformační pravidla** – vložení, smazání, přesun, změna-rysu, kopie-rysu transformace převádí hloubkové struktury na struktury povrchové


Příklad bázové komponenty

pravidla:

$S \rightarrow NP\ VP$
 $NP \rightarrow (D) A^* N PP^*$
 $VP \rightarrow V (NP) (PP)$
 $PP \rightarrow P NP$

věta: Ten starý lovec se psem šli do lesa.

syntaktický strom:



Návrh podkladů a datových struktur

- ▶ **syntaktický strom** – kompletní **hierarchický popis struktury** věty
- ▶ **úkol syntaktické analýzy** = pro danou gramatiku a daný vstup (větu) dát **všechny syntaktické stromy**
- ▶ existují techniky pro kompaktní uložení **lesa** takových stromů (chart parsing)
- ▶ jelikož se zabýváme výhradně syntaktickou strukturou a nevylučujeme a priori strukturní stromy s absurdní interpretací, má většina vět mnoho různých syntaktických stromů

Obehnat Šalounův pomník mistra Jana Husa na pražském Staroměstském náměstí živým plotem z hustých keřů s trny navrhuje občanské sdružení Společnost Jana Jesenia.

Pocet uspesnych stromu = 57 102 672

lexikon:

D: ten, ta
A: velký, hnědý, starý
N: pták, psem, lovec, já, lesa
V: loví, jí, šli
P: se, do

Příklad transformačních pravidel

např. **pasivizace** (v angličtině):

John chose a book.

NP1 – V – NP2

1 – 2 – 3 → 3 – 2+be+en – by+1

přesuny + vložení + změny-rysu

- ▶ transformace:

- **obligatorní** – např. přesun slovesné koncovky za sloveso
- **fakultativní** – např. pasivizace, tvorba otázek, negace (změna významu)

- ▶ pravidla bázové komponenty – popisují strom hloubkové struktury v obvyklém pořadí
- ▶ transformace umožňují jeho změny na různé povrchové varianty (trpný rod, otázka, ...)
- ▶ **stopa (trace)** – ukazuje, kde byl prvek před přemístěním

Návrh podkladů a datových struktur – pokrač.

Automatická analýza syntaxe musí vždy projít třemi fázemi:

1. musí být zvolena notace pro zápis gramatiky – **gramatický formalismus**
2. musí být ve zvoleném formalismu napsána **gramatika** pro každý jazyk, který bude zpracováván
3. musí být vybrán nebo navržen **algoritmus**, který určí, zda daný vstup odpovídá gramatice, a pokud ano, jaký popis mu odpovídá