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

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**

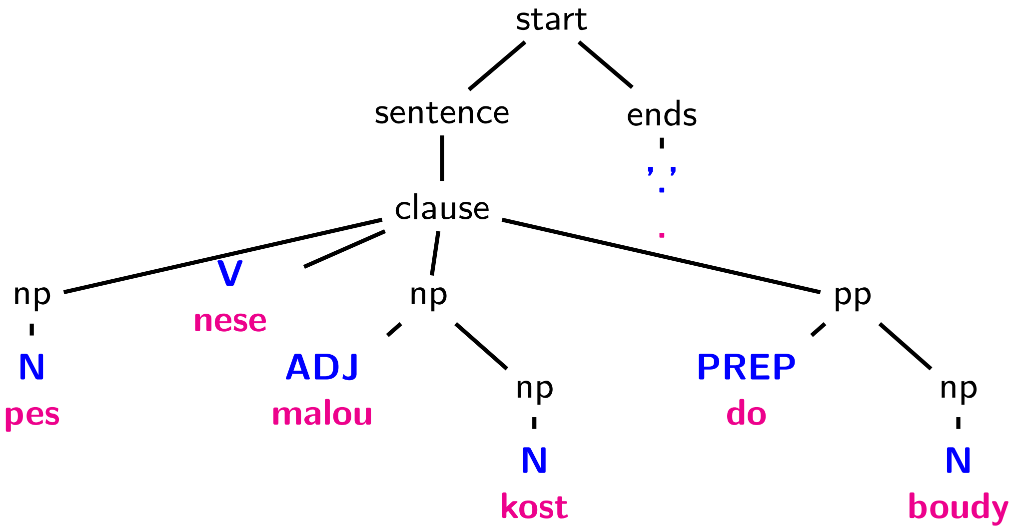

Syntaktická analýza programovacích × přirozených jazyků

- 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

Typy gramatik

gramatiky:

- regulární (regular)   neterminál → **terminál**[neterminál]

  S → **a**S
  S → **b**

  ekvivalentní síle **konečných automatů**, neumí $a^n b^n$
- bezkontextové (context-free)   neterminál → cokoliv

  S → **a**S**b**

  ekvivalentní síle **zásobníkových automatů**, umí $a^n b^n$, neumí $a^n b^n c^n$
- kontextové (context-sensitive) – víc termů na levé straně (*kontext* neterminálu); na levé straně se počet termů "zmenšuje"

  ASB → AA**a**BB

  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 faktem, že rodilí mluvčí nemívají potíže s pochopením významu vět
- asi **nejstarší formální popis jazyka** – gramatika sanskrtu od indického učence Paniniho

  - 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

- 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	$\rightarrow$	pes	|	člověk	|	dům ...
V	$\rightarrow$	nese	|	chodit	|	psal ...
ADJ	$\rightarrow$	...				
PREP	$\rightarrow$	...				
ADV	$\rightarrow$	...				

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

Základní termíny – pokrač.

- frázová kategorie (*phrasal category*)
  neterminální symbol gramatiky, který nevyjadřuje lexikální kategorii

ADJP	$\rightarrow$	ADJP	ADJ
NP	$\rightarrow$	ADJP	N
VP	$\rightarrow$	V	NP
S	$\rightarrow$	NP	VP

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

Základní termíny – pokrač.

- větná struktura (*sentence structure*) – strukturovaný popis větných členů
  - povrchová struktura (*surface structure*)

    derivační/složkový strom
    jako výsledek bezkontextové (CF) analýzy

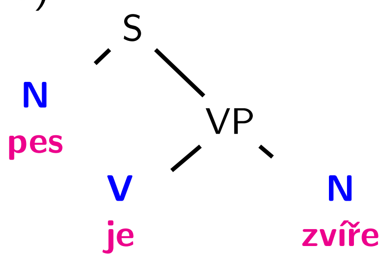

  - závislostní struktura (*dependency structure*)

    zobrazuje závislosti mezi větnými členy

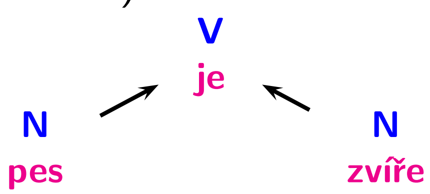

  - hloubková struktura (*deep structure*) – sémantická interpretace fráze.
    Popisuje **role větných členů** (agens, patiens, donor, cause, . . .)

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 – 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

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.

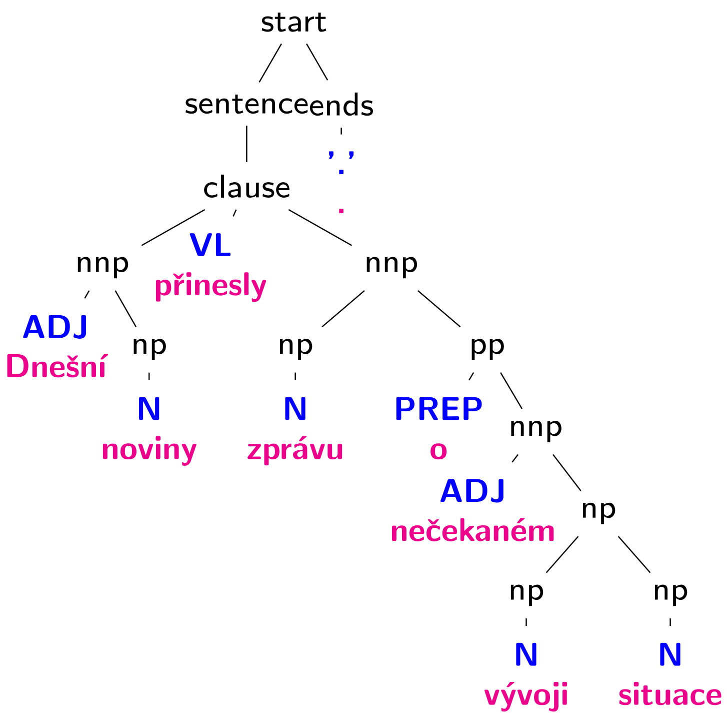

Uzly syntaktického stromupokrač.

- **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

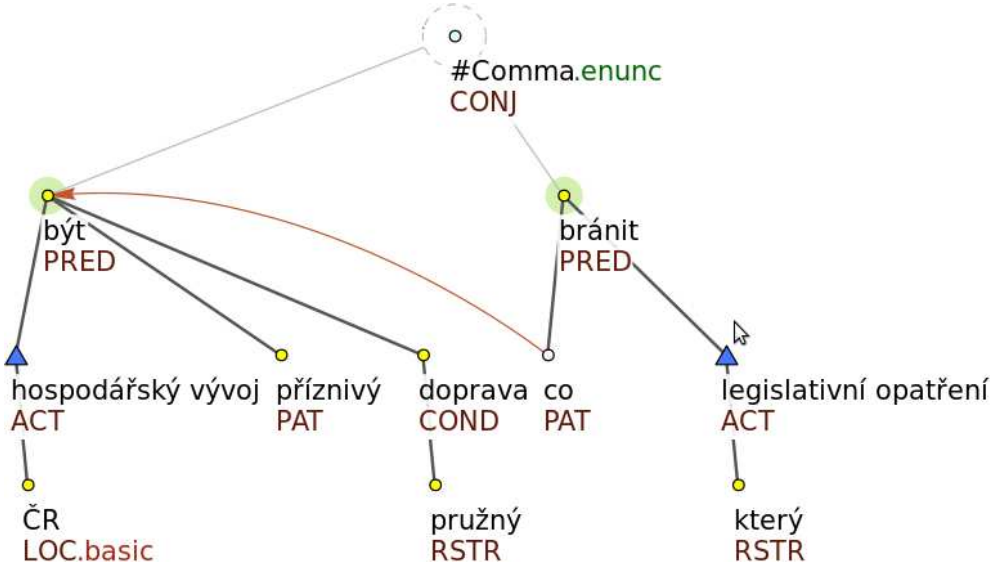

Příznaky a příznakové struktury

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**

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

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 **matice** dvojic atribut–hodnota.
- u složitějších struktur – nestačí pak běžné porovnání instanciace jde oběma směry → použije se **unifikace**

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**

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 = stavy 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**
  $\Leftarrow$ 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
- znalost 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 vázání, 1981), která zakládá 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 → NP VP
NP → (D) A* N PP*
VP → V (NP) (PP)
PP → P NP

lexikon:

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

věta: `Ten starý lovec se psem šli do lesa.`

syntaktický strom:

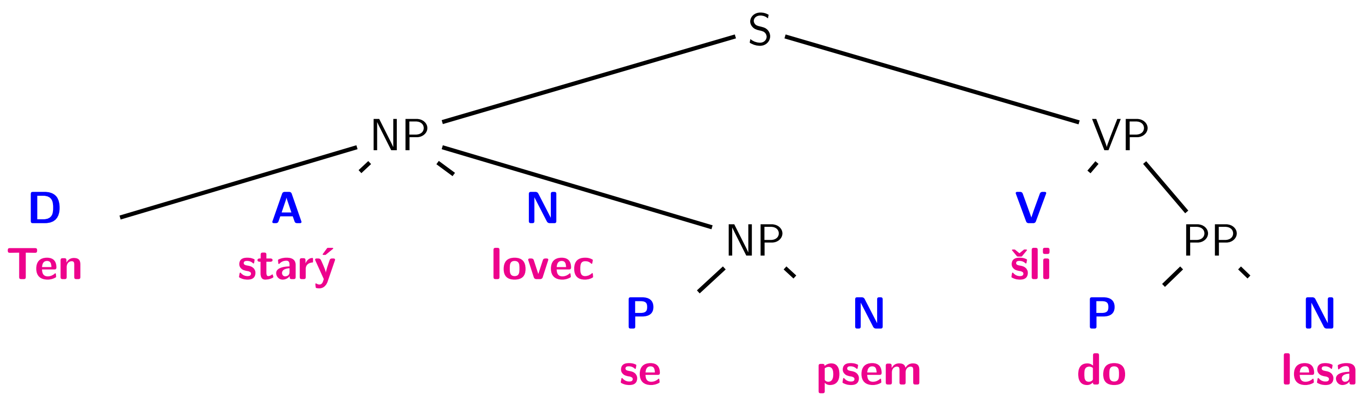

Příklad transformačních pravidel

např. **pasivizace** (v angličtině):

John chose a book.

NP1 – Aux – V – NP2
1 – 2 – 3 – 4 $\rightarrow$ 4 – 2+be+en – 3 – 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

- **syntaktický** (odvozovací, derivační) frázový **strom** – kompletní hierarchický popis struktury věty
- úkol syntaktické analýzy = pro danou gramatiku a daný vstup (větu) dát všechny odvozovací stromy
- existují techniky pro kompaktní uložení **lesa** takových stromů (chart parsing)
- jelikož se zabýváme výhradně syntaktickou strukturou a nevylučujeme a priori derivační 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

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