

# Syntaxe – gramatiky a syntaktické struktury

Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)

[http://nlp.fi.muni.cz/nlp\\_intro/](http://nlp.fi.muni.cz/nlp_intro/)

Obsah:

- Aktualita - ChatGPT-4
- Syntaxe, syntaktická analýza
- Specifikace gramatik
- Chomského teorie syntaxe
- Východiska syntaktické analýzy

# Aktualita - ChatGPT-4

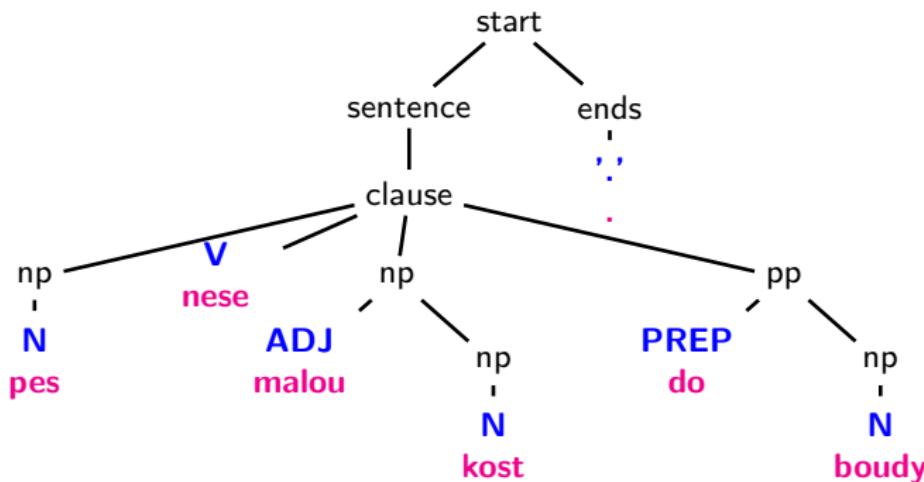
<https://openai.com/product/gpt-4>

- OpenAI oznámila 14.3.2023 vydání nové verze modelu **ChatGPT-4**
- nástupce aktuálního **ChatGPT-3.5**, zatím **není veřejně** dostupný aktuální plán – pouze **placený** přístup
- **není** zveřejněný počet trénovaných **parametrů** (GPT-3 175 miliard)
- novinky:
  - textový i **obrazový** vstup
  - delší **kontext** až 25 tisíc slov (cca 52 stran textu)
  - úspěšnější v řešení úloh ze **soutěží** (10 vs 90 percentil)
  - stále **halucinuje**, ale v **80 %** odpovídá **správně**
  - **bezpečnější** opovědi
  - využití v **Khan Academy**, **Duolingo**, **Be My Eyes**, ...



# 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**



# 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. **preterminál** 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

- **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. **preterminál** 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 kategorie

ADJP → ADJP ADJ

NP → ADJP N

VP → V NP

S → NP VP

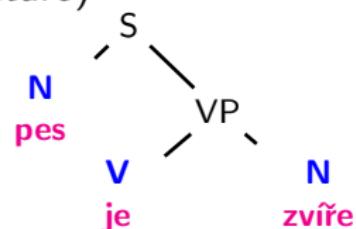
- **větný člen** (*constituent*) – lexikální nebo frázová kategorie

# Základní termíny – pokrač.

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

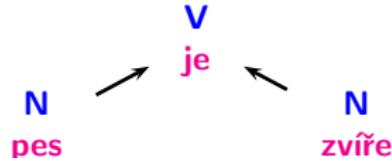
- povrchová struktura (*surface structure*)

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, ...)

# 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

# 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

# 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]**

$$\begin{array}{l} S \rightarrow aS \\ S \rightarrow b \end{array}$$

ekvivalentní síle konečných automatů,  
neumí  $a^n b^n$

- bezkontextové (context-free)      neterminál → cokoliv

$$S \rightarrow aSb$$

ekvivalentní síle zásobníkových  
automatů, umí  $a^n b^n$ , neumí  $a^n b^n c^n$

- kontextové (context-sensitive) – více termů na levé straně (*kontext*  
neterminálu)

$$\underline{ASB} \rightarrow \underline{AaBcB}$$

ekvivalentní síle lineárně ohra-  
ničeného Turingova stroje,  
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

# Typy gramatik

gramatiky:

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

$$\begin{array}{l} S \rightarrow aS \\ S \rightarrow b \end{array}$$

ekvivalentní síle konečných automatů,  
neumí  $a^n b^n$

- bezkontextové (context-free)      neterminál → cokoliv

$$S \rightarrow aSb$$

ekvivalentní síle zásobníkových  
automatů, umí  $a^n b^n$ , neumí  $a^n b^n c^n$

- kontextové (context-sensitive) – více termů na levé straně (*kontext neterminálu*)

$$\underline{ASB} \rightarrow \underline{AaBcB}$$

ekvivalentní síle lineárně ohra-  
ničeného Turingova stroje,  
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

# Typy gramatik

gramatiky:

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

$$\begin{array}{l} S \rightarrow aS \\ S \rightarrow b \end{array}$$

ekvivalentní síle konečných automatů,  
neumí  $a^n b^n$

- bezkontextové (context-free)      neterminál → cokoliv

$$S \rightarrow aSb$$

ekvivalentní síle zásobníkových  
automatů, umí  $a^n b^n$ , neumí  $a^n b^n c^n$

- kontextové (context-sensitive) – více termů na levé straně (*kontext neterminálu*)

$$\underline{ASB} \rightarrow \underline{AaBcB}$$

ekvivalentní síle lineárně ohra-  
ničeného Turingova stroje,  
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

# Typy gramatik

gramatiky:

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

$$\begin{array}{l} S \rightarrow aS \\ S \rightarrow b \end{array}$$

ekvivalentní síle konečných automatů,  
neumí  $a^n b^n$

- bezkontextové (context-free)      neterminál → cokoliv

$$S \rightarrow aSb$$

ekvivalentní síle zásobníkových  
automatů, umí  $a^n b^n$ , neumí  $a^n b^n c^n$

- kontextové (context-sensitive) – více termů na levé straně (*kontext neterminálu*)

$$\underline{ASB} \rightarrow \underline{AaBcB}$$

ekvivalentní síle lineárně ohra-  
ničeného Turingova stroje,  
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

# Typy gramatik

gramatiky:

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

$$\begin{array}{l} S \rightarrow aS \\ S \rightarrow b \end{array}$$

ekvivalentní síle konečných automatů,  
neumí  $a^n b^n$

- bezkontextové (context-free)      neterminál → cokoliv

$$S \rightarrow aSb$$

ekvivalentní síle zásobníkových  
automatů, umí  $a^n b^n$ , neumí  $a^n b^n c^n$

- kontextové (context-sensitive) – více termů na levé straně (*kontext neterminálu*)

$$\underline{ASB} \rightarrow \underline{AaBcB}$$

ekvivalentní síle lineárně ohra-  
ničeného Turingova stroje,  
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 Paninihu
  - 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

# 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 Paninihu



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

# Obsah

## 1 Aktualita - ChatGPT-4

## 2 Syntaxe, syntaktická analýza

- Základní termíny
- Analýza programovacích a přirozených jazyků
- Gramatiky přirozeného jazyka

## 3 Specifikace gramatik

- Složkový a závislostní přístup
- Uzly syntaktického stromu
- Pořádek slov ve větě
- Možnosti zadávání gramatik

## 4 Chomského teorie syntaxe

- Standardní teorie syntaxe

## 5 Východiska syntaktické analýzy

- Návrh podkladů a datových struktur
- Grammatical Framework

# 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

dva základní způsoby zadávání gramatik

## složkový přístup:

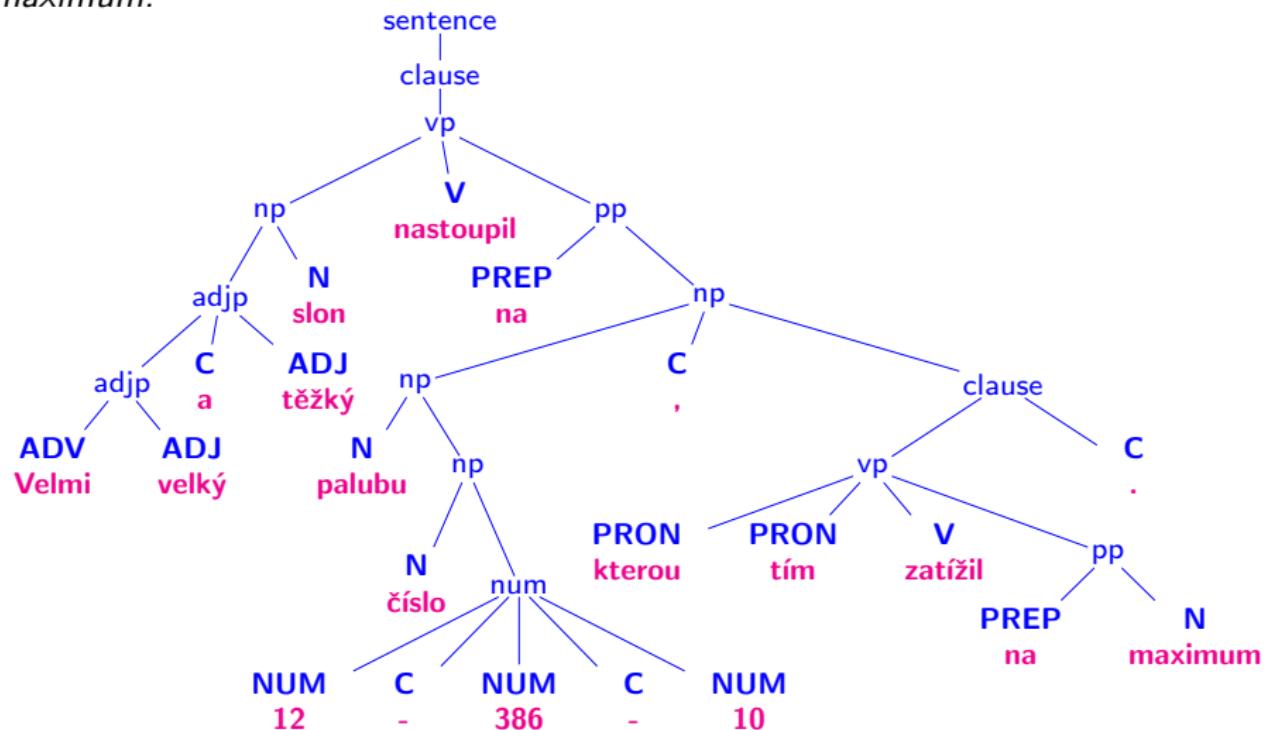
- skupiny slov tvoří větné jednotky, které jsou označovány jako **fráze**, a jako **větné členy** (*složky, constituents*) formují **větu**
- např.

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 – složkové stromy

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



# 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.

## 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.

## závislostní přístup:

- jeden člen vazby je označován jako **řídící**, druhý jako **závislý**
- např.

přídavné jméno závisí na řídícím podstatném jménu

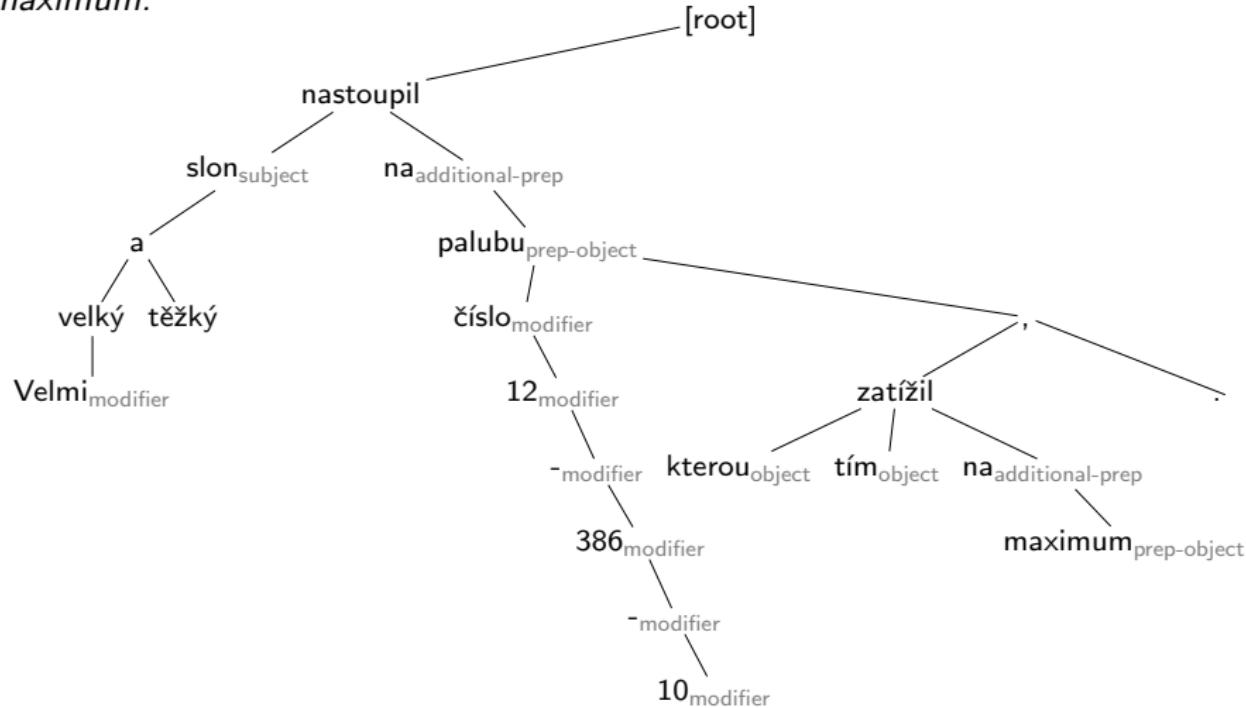
- syntaktická struktura věty je zachycována pomocí **závislostního stromu**:
  - *uzly* odpovídají elementárním jednotkám vstupu (často slovům)
  - *hrany* označují vztahy závislosti mezi elementárními jednotkami
- závislost není relací mezi jednotlivými slovy, ale obecně relací mezi jedním **slovem 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 – 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 – 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 – pokrač.

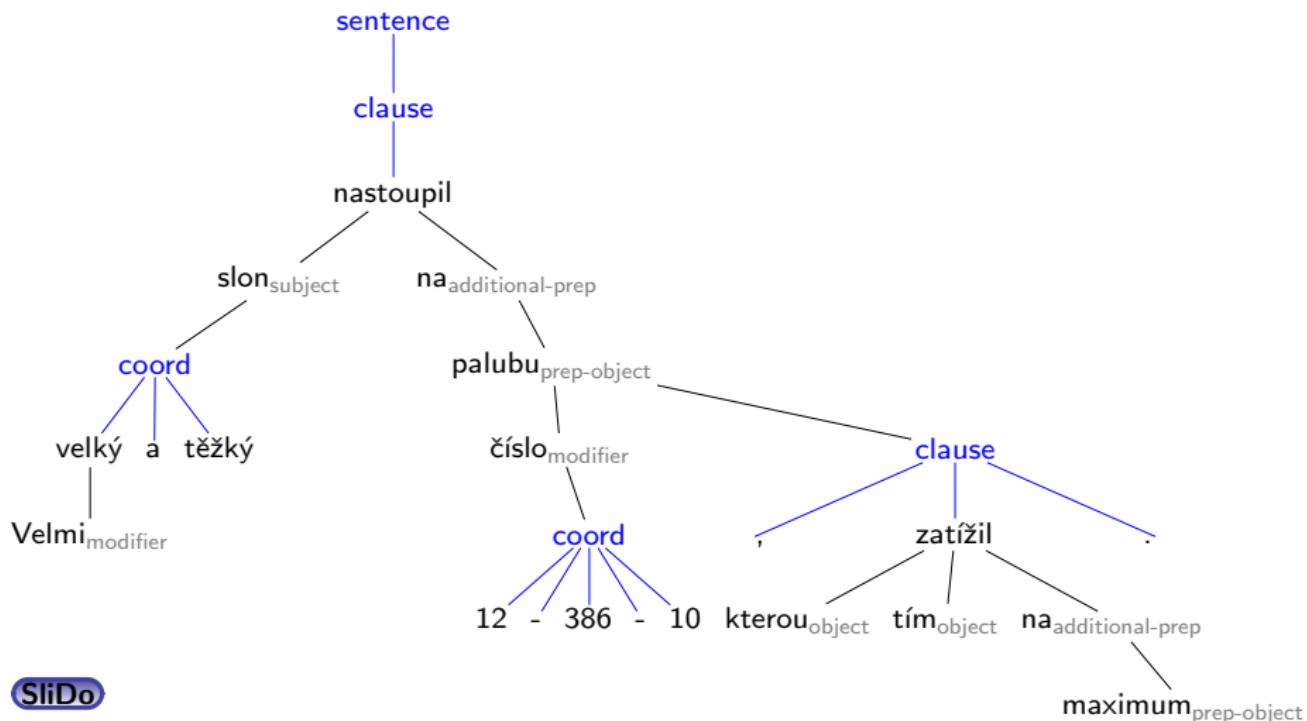
- jen zřídka se používá čistě složkový či striktně závislostní přístup
- ve složkovém jsou závislosti zpravidla vyjádřeny přidáním označení, která složka je řídící pro danou frázi
- závislostní strom bývá doplněn o informaci určující lineární precedenci
- je možné pak mezi těmito přístupy výsledek převádět

# Složkový a závislostní přístup – 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.*

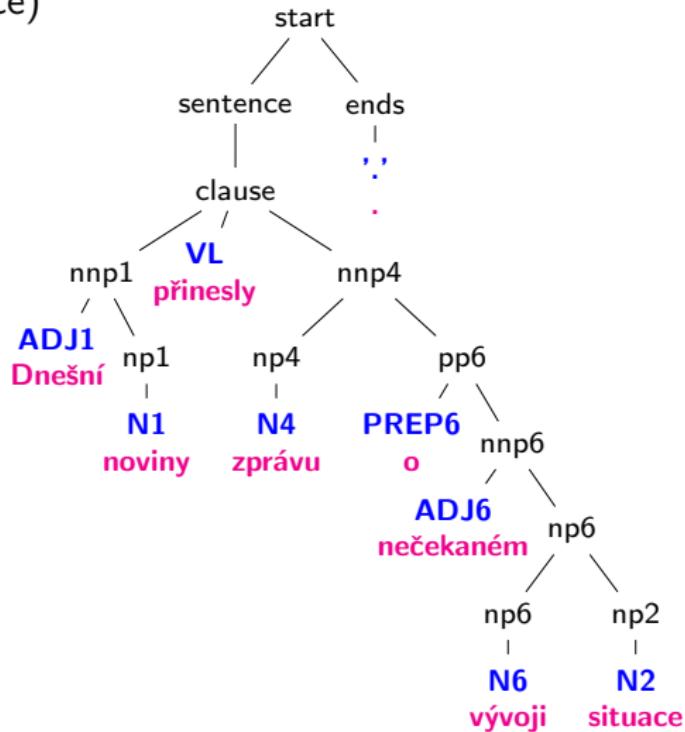


# Uzly syntaktického stromu

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 (1.pád)**, NP v roli **předmětu (4.pád)**, ADVP určující **lokaci (předl. skupina se 6.pádem)** 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.

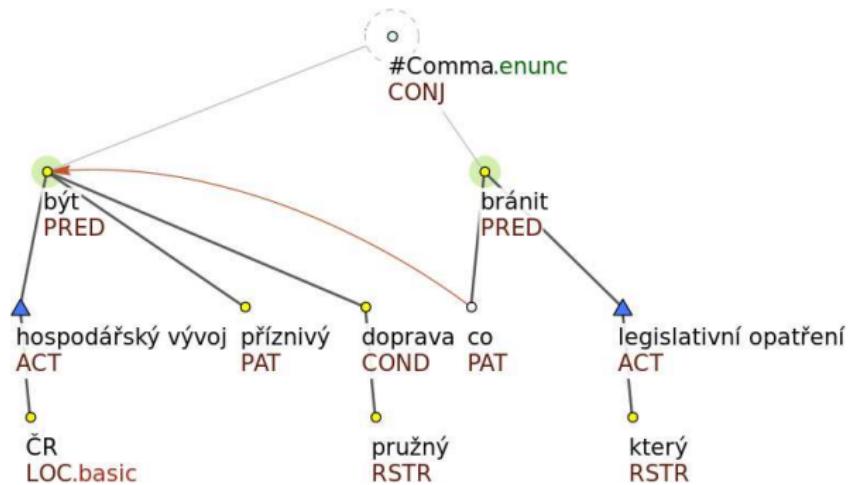


# Uzly syntaktického stromu – pokrač.

- tematická role (též hloubkový/sémantický pád)

- na rozdíl od gramatické role se jedná o **sémantickou kategorii**
- určujeme např.:
  - Agens** – kdo je životním *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/risy (features)** – zaznamenávají **syntaktické nebo sémantické informace** o slovu nebo frázi.

např. **test na shodu**:

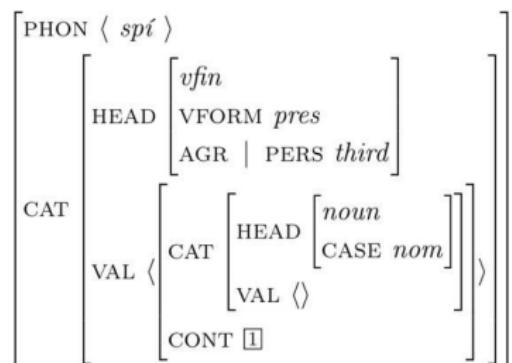
Malý Petr přišel domů.

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**

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

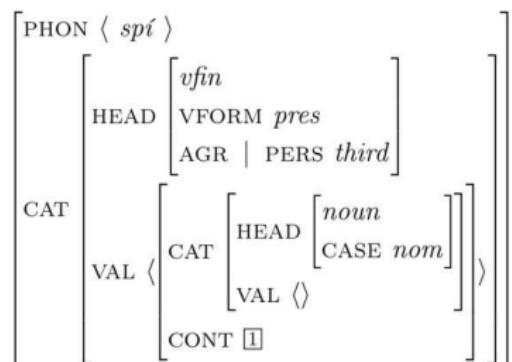
# Příznaky a příznakové struktury – pokrač.

- 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**



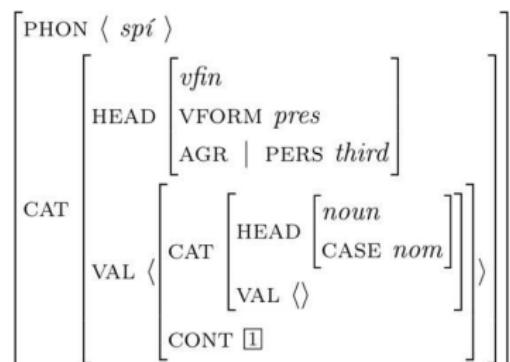
# Příznaky a příznakové struktury – pokrač.

- 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**



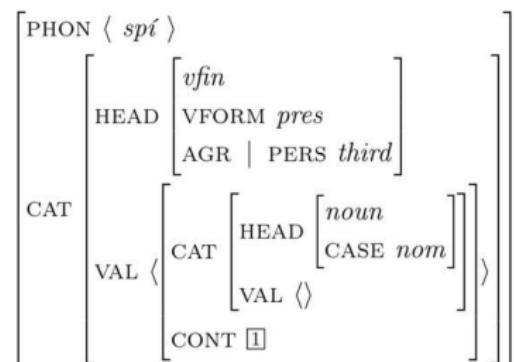
# Příznaky a příznakové struktury – pokrač.

- 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**



# 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**



# 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**

**SliDo**

# 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**

SliDo

# Možnosti zadávání gramatik

- nejčastější formát specifikace gramatik – **produkční pravidla**  
gramatika se skládá z pravidel generujících **správně utvořené řetězce**

```
S      →  NP   VP  
NP    →  Člověk  
VP    →  myslí
```

- 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

# Možnosti zadávání gramatik

- nejčastější formát specifikace gramatik – **produkční pravidla**  
gramatika se skládá z pravidel generujících **správně utvořené řetězce**

```
S      →  NP   VP  
NP    →  Člověk  
VP    →  myslí
```

- 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

# Možnosti zadávání gramatik

- nejčastější formát specifikace gramatik – **produkční pravidla**  
gramatika se skládá z pravidel generujících **správně utvořené řetězce**

```
S      →  NP   VP  
NP    →  Člověk  
VP    →  myslí
```

- 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**

# Obsah

## 1 Aktualita - ChatGPT-4

## 2 Syntaxe, syntaktická analýza

- Základní termíny
- Analýza programovacích a přirozených jazyků
- Gramatiky přirozeného jazyka

## 3 Specifikace gramatik

- Složkový a závislostní přístup
- Uzly syntaktického stromu
- Pořádek slov ve větě
- Možnosti zadávání gramatik

## 4 Chomského teorie syntaxe

- Standardní teorie syntaxe

## 5 Východiska syntaktické analýzy

- Návrh podkladů a datových struktur
- Grammatical Framework

# 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

# 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

# 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

# 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

# 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

# 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

# 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 vázání, 1981), která zakládá na pojmu *univerzální gramatiky*
  - 90. léta – teorie **minimalismu** (snaha po úspornosti popisného aparátu)

# 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.

- 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:

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

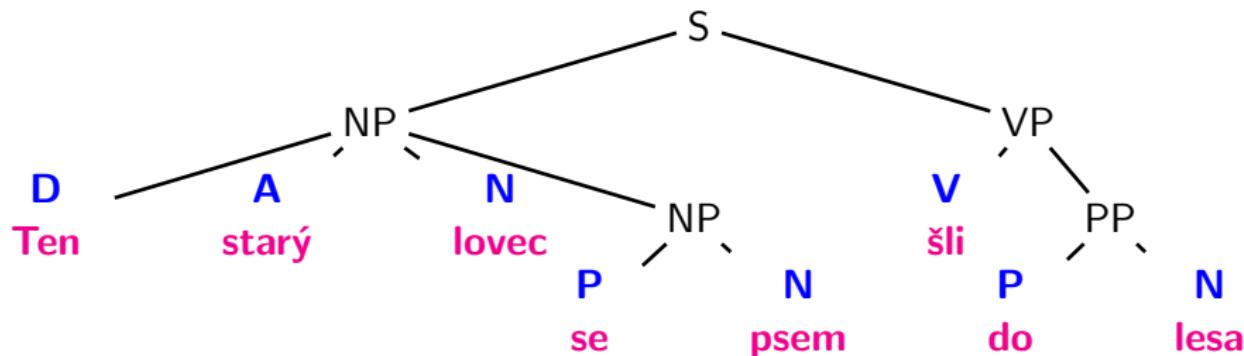
lexikon:

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 – 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

# 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-rysů

- 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

# 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-rysů

- 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

# 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-rysů

- 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

# 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-rysů

- 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

# Obsah

## 1 Aktualita - ChatGPT-4

## 2 Syntaxe, syntaktická analýza

- Základní termíny
- Analýza programovacích a přirozených jazyků
- Gramatiky přirozeného jazyka

## 3 Specifikace gramatik

- Složkový a závislostní přístup
- Uzly syntaktického stromu
- Pořádek slov ve větě
- Možnosti zadávání gramatik

## 4 Chomského teorie syntaxe

- Standardní teorie syntaxe

## 5 Východiska syntaktické analýzy

- Návrh podkladů a datových struktur
- Grammatical Framework

# 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 = 3 610 464

# 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 = 3 610 464

# 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 = 3 610 464

# 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 = 3 610 464

# 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

# 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

# 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

# Grammatical Framework



[www.grammaticalframework.org](http://www.grammaticalframework.org)

- odděluje **abstraktní** a **konkrétní** gramatiky
  - návrh gramatik **desítek jazyků**
  - popis gramatiky využívá pro **analýzu** i generování (tzv. *linearizace*)
  - abstraktní gramatika může sloužit jako **interlingua** při překladu desítky navazujících aplikací
- <http://www.grammaticalframework.org/demos/>

# Grammatical Framework



[www.grammaticalframework.org](http://www.grammaticalframework.org)

- odděluje **abstraktní** a **konkrétní** gramatiky
  - návrh gramatik **desítek** jazyků
  - popis gramatiky využívá pro **analýzu** i generování (tzv. *linearizace*)
  - abstraktní gramatika může sloužit jako **interlingua** při překladu desítky navazujících aplikací
- <http://www.grammaticalframework.org/demos/>

# Grammatical Framework



[www.grammaticalframework.org](http://www.grammaticalframework.org)

- odděluje **abstraktní** a **konkrétní** gramatiky
- návrh gramatik **desítek** jazyků
- popis gramatiky využívá pro **analýzu** i generování (tzv. *linearizace*)
- abstraktní gramatika může sloužit jako **interlingua** při překladu desítky navazujících aplikací

<http://www.grammaticalframework.org/demos/>

# Grammatical Framework



[www.grammaticalframework.org](http://www.grammaticalframework.org)

- odděluje **abstraktní** a **konkrétní** gramatiky
  - návrh gramatik **desítek** jazyků
  - popis gramatiky využívá pro **analýzu** i generování (tzv. *linearizace*)
  - abstraktní gramatika může sloužit jako **interlingua** při překladu desítky navazujících aplikací
- <http://www.grammaticalframework.org/demos/>

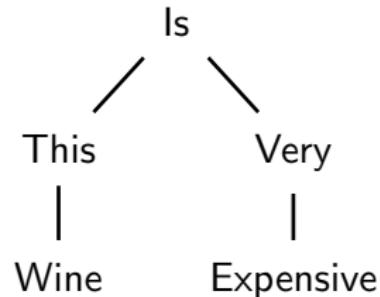
# Grammatical Framework – abstraktní gramatika

```

1 abstract Food = {
2
3   cat Kind;
4   fun Wine : Kind;
5   fun Cheese : Kind;
6   fun Fish : Kind;
7
8   cat Item;
9   fun The : Kind -> Item;
10  fun This : Kind -> Item;
11
12  cat Quality;
13  fun Delicious : Quality;
14  fun Expensive : Quality;
15  fun Fresh : Quality;
16  fun Very : Quality -> Quality;
17
18  cat Phrase;
19  fun Is : Item -> Quality -> Phrase;
20
21 flags startcat = Phrase;
22 }

```

Is (This Wine) (Very Expensive)



# Grammatical Framework – konkrétní gramatika Eng

```
1 concrete FoodEng of Food = {  
2  
3   lincat Kind = {s : Str};  
4   lin Wine = {s = "wine"};  
5   lin Cheese = {s = "cheese"};  
6   lin Fish = {s = "fish"};  
7  
8   lincat Item = {s : Str};  
9   lin The kind = {s = "the" ++ kind.s};  
10  lin This kind = {s = "this" ++ kind.s};  
11  
12  lincat Quality = {s : Str};  
13  lin Delicious = {s = "delicious"};  
14  lin Expensive = {s = "expensive"};  
15  lin Fresh = {s = "fresh"};  
16  lin Very quality = {s = "very" ++ quality.s};  
17  
18  lincat Phrase = {s : Str};  
19  lin Is item quality = {s = item.s ++ "is" ++ quality.s};  
20  
21 }
```

# Grammatical Framework – konkrétní gramatika CZ

```

1 concrete FoodCze of Food = {
2
3   param Gender = Masc | Fem | Neut;
4
5   lincat Kind = {s : Str; g : Gender};
6   lin Wine = {s = "vino"; g = Neut};
7   lin Cheese = {s = "sýr"; g = Masc};
8   lin Fish = {s = "ryba"; g = Fem};
9
10  lincat Item = {s : Str; g : Gender};
11  lin The kind = {
12    s = case kind.g of {Masc => "ten"; Fem => "ta"; Neut => "to"} ++ kind.s;
13    g = kind.g
14  };
15  lin This kind = {
16    s = case kind.g of {Masc => "tento"; Fem => "tato"; Neut => "toto"} ++ kind.s;
17    g = kind.g
18  };
19
20  lincat Quality = {s : Gender => Str};
21  lin Delicious = {
22    s = table {Masc => "dobrý"; Fem => "dobrá"; Neut => "dobré"}
23  };
24  lin Expensive = {
25    s = table {Masc => "drahý"; Fem => "drahá"; Neut => "drahé"}
26  };
27  lin Fresh = {
28    s = table {Masc => "čerstvý"; Fem => "čerstvá"; Neut => "čerstvé"}
29  };
30  lin Very quality = {
31    s = table {g => "velmi" ++ quality.s!g}
32  };
33
34  lincat Phrase = {s : Str};
35  lin Is item quality = {s = item.s ++ "je" ++ quality.s!item.g};

```

# Grammatical Framework – překlad

```
> import Food.gr
linking ... OK

Food> import FoodEng.gf
linking ... OK

Languages: FoodEng
0 msec
Food> import FoodCze.gf
linking ... OK

Languages: FoodCze FoodEng
4 msec
Food> linearize Is (This Cheese) Delicious
tento sýr je dobrý
this cheese is delicious

4 msec
Food> parse -lang=Eng "this wine is expensive" | linearize -lang=Cze
toto víno je velmi drahé
```

viz možnosti např. na [www.phrasomatic.net](http://www.phrasomatic.net)