

## Týden 6

### Přednáška

#### Redukce bezkontextových gramatik

Připomněli jsme si relaci  $\Rightarrow$  na množině  $(\Pi \cup \Sigma)^*$  pro danou bezkontextovou gramatiku  $G = (\Pi, \Sigma, S, P)$ . Také jsme si obecně připomněli *reflexivní a tranzitivní uzávěr* relace, konkrétně pak relaci  $\Rightarrow^*$ .

Víme tedy, že (pro danou  $G$ ) je  $\Rightarrow^*$  nejmenší množinou dvojic  $(\alpha, \beta) \in (\Pi \cup \Sigma)^* \times (\Pi \cup \Sigma)^*$  splňující následující tři podmínky (pro každé  $\alpha, \beta, \gamma \in (\Pi \cup \Sigma)^*$ ):

- $\alpha \Rightarrow^* \alpha$ ;
- $(\alpha \Rightarrow \beta, \beta \Rightarrow^* \gamma) \implies \alpha \Rightarrow^* \gamma$ .

Na konkrétním příkladu

$$\begin{aligned} S &\longrightarrow aSb \mid aAbb \mid \varepsilon \\ A &\longrightarrow aAB \mid bB \\ B &\longrightarrow aAb \mid BB \\ C &\longrightarrow CC \mid cS \end{aligned}$$

jsme se pak zabývali redukcí bezkontextové gramatiky.

Přitom jsme obecně pro gramatiku  $G = (\Pi, \Sigma, S, P)$  definovali množinu  $\mathcal{D}_G$  (značenou  $\mathcal{D}$ , když  $G$  je z kontextu jasná) následující induktivní definicí. (Tedy  $\mathcal{D}$  je nejmenší množina splňující následující podmínky.)

- $S \in \mathcal{D}$ ;
- $(X \in \mathcal{D}, (X \longrightarrow \alpha Y \beta) \in P, Y \in \Pi) \implies Y \in \mathcal{D}$ .

Je vidět, že  $\mathcal{D}$  obsahuje všechny dosažitelné neterminály, tedy takové, které se mohou objevit v nějakém odvození z počátečního  $S$  (byť to odvození nemusí třeba skončit terminálním slovem). Tedy  $\mathcal{D} = \{ Z \in \Pi \mid \exists \alpha, \beta : S \Rightarrow^* \alpha Z \beta \}$ .

Množinu  $\mathcal{T}_G$  (či  $\mathcal{T}$ ) všech neterminálů, z nichž lze odvodit alespoň jedno terminální slovo, tedy množinu  $\mathcal{T} = \{ Z \in \Pi \mid \exists u \in \Sigma^* : Z \Rightarrow^* u \}$ , můžeme definovat induktivní definicí s jedinou podmínkou:

- $((X \longrightarrow \alpha) \in P, \alpha \in (\Sigma \cup \mathcal{T})^*) \implies X \in \mathcal{T}$ .

Obě definice dávají očividné návody k algoritmické konstrukci příslušných množin; ty jsme si také ujasnili a provedli.

(Poznámka. Na minulém cvičení jsme u definice  $\mathcal{T}$  uvedli dvě podmínky. Vypíchlí jsme totiž zvlášť případ  $\alpha \in \Sigma^*$ , na jehož základě zjistí algoritmus ty neterminály, které odvodí terminální slovo jedním krokem.)

*Definice.* Gramatika  $G = (\Pi, \Sigma, S, P)$  je *redukována*, jestliže  $\mathcal{D}_G = \mathcal{T}_G = \Pi$ .

Zjistili jsme, že pro zredukování gramatiky  $G$  je vhodné nejdříve zjistit množinu  $\mathcal{T}_G$  a odstranit z  $G$  všechna pravidla, která obsahují alespoň jeden neterminál, který není v  $\mathcal{T}_G$ . Výsledná gramatika  $G'$  očividně generuje tentýž jazyk jako  $G$ .

(Co to znamená, když nic nezůstane, tedy ani  $S$  nepatří do  $\mathcal{T}_G$  ? Samozřejmě  $L(G) = \emptyset$ .)

Pro  $G'$  nyní zkonstruujeme množinu  $\mathcal{D}_{G'}$  a odstraníme všechna pravidla, která obsahují neterminál(y), jež nejsou v  $\mathcal{D}_{G'}$ . Výsledná gramatika  $G''$  je již redukována.

De facto jsme tak ukázali následující větu.

*Věta.* Ke každé BG  $G$ , pro niž  $L(G) \neq \emptyset$ , lze sestavit redukovanou gramatiku  $G'$  tž.  $L(G') = L(G)$ .

Poznámka. Opačný postup, tj. odstranění nedosažitelných neterminálů a poté odstranění těch, které neodvodí terminální slovo, k redukované gramatice vést nemusí. To ilustruje např. gramatika s pravidly  $S \rightarrow a$ ,  $S \rightarrow XY$ ,  $X \rightarrow bX$ ,  $Y \rightarrow a$ .

### Speciální formy bezkontextových gramatik

Připomněli jsme si, co jsou *nevypouštějící gramatiky*; tyto gramatiky nemají pravidla typu  $X \rightarrow \varepsilon$ . Algoritmus převodu obecné bezkontextové gramatiky  $G$  na nevypouštějící gramatiku  $G'$  takovou, že  $L(G') = L(G) - \{\varepsilon\}$ , navrhnete na cvičení. Tím bude jasná následující věta.

*Věta.* Ke každé BG  $G$  lze sestavit nevypouštějící gramatiku  $G'$  tž.  $L(G') = L(G) - \{\varepsilon\}$ .

Poté jsme si připomněli gramatiky v *Chomského normální formě*. Taková gramatika má výhradně pravidla ve tvarech  $X \rightarrow YZ$  a  $X \rightarrow a$ . Tedy na pravé straně každého pravidla je buď jeden terminál nebo dva neterminály. Ilustrovali jsme si konstrukci, která dokazuje následující větu.

*Věta.* Ke každé BG  $G$  lze sestavit BG  $G'$  v ChNF tž.  $L(G') = L(G) - \{\varepsilon\}$ .

Převod gramatiky  $G$  do ChNF se dá rozdělit do čtyř kroků:

- převod na nevypouštějící gramatiku,
- odstranění pravidel typu  $X \rightarrow Y$ ,
- pro každý terminál  $a$  přidáme nový neterminál  $A_a$  a pravidlo  $A_a \rightarrow a$ ; na každé pravé straně delší než 1 nahradíme  $a$  neterminálem  $A_a$ ,
- každé pravidlo typu  $X \rightarrow Y_1Y_2 \dots Y_n$ , kde  $n \geq 3$ , nahradíme pravidly

$$\begin{aligned} X &\rightarrow Y_1Z_1, \\ Z_1 &\rightarrow Y_2Z_2, \\ &\dots\dots \\ Z_{n-3} &\rightarrow Y_{n-2}Z_{n-2}, \\ Z_{n-2} &\rightarrow Y_{n-1}Y_n \end{aligned}$$

kde  $Z_1, Z_2, \dots, Z_{n-2}$  jsou nově přidané neterminály.

Některé myšlenky převodu jsme načrtli na příkladu následující gramatiky.

$$\begin{aligned} S &\longrightarrow (E) \mid E \\ E &\longrightarrow F + F \mid F \times F \\ F &\longrightarrow a \mid S \end{aligned}$$

Připomeňme ještě gramatiky v *Greibachově normální formě* (GNF). Taková gramatika má výhradně pravidla ve tvarech  $X \longrightarrow a\alpha$ , kde  $a$  je terminál a  $\alpha$  je řetězec neterminálů (třeba prázdný). Platí také následující věta.

*Věta.* Ke každé BG  $G$  lze sestavit BG  $G'$  v GNF tž.  $L(G') = L(G) - \{\varepsilon\}$ .

### Zásobníkové automaty

Uvedli jsme neformálně model „zásobníkový automat“ (ZA) a zkonstruovali jsme konkrétní ZA  $M$  přijímající jazyk

$$L = \{wcw^R \mid w \in \{a, b\}^*\}.$$

(Sestavili jsme patřičnou množinu instrukcí typu  $(q, a, X) \rightarrow (q', \alpha)$ .)

Zároveň jsme uvedli formální definici zásobníkového automatu jako struktury

$$M = (Q, \Sigma, \Gamma, \delta, q_0, Z_0),$$

kde  $Q$  je konečná množina *stavů*,  $\Sigma$  je konečná *vstupní abeceda*,  $\Gamma$  je konečná *zásobníková abeceda*,  $q_0 \in Q$  je *počáteční stav*,  $Z_0 \in \Gamma$  je *počáteční zásobníkový symbol* a

$$\delta : Q \times (\Sigma \cup \{\varepsilon\}) \times \Gamma \rightarrow \mathcal{P}_{fin}(Q \times \Gamma^*)$$

je přechodová funkce (neboli konečná množina instrukcí).

Definovali jsme *konfiguraci* ZA  $M$  jako trojici  $(q, w, \alpha)$ , kde  $q \in Q$ ,  $w \in \Sigma^*$ ,  $\alpha \in \Gamma^*$ .

Na množině takových konfigurací přirozeně definujeme relaci  $\vdash_M$  (odvození v jednom kroku):

$$(q, aw, X\beta) \vdash_M (q', w, \alpha\beta) \Leftrightarrow \delta(q, a, X) \ni (q', \alpha)$$

(kde  $a \in (\Sigma \cup \{\varepsilon\})$ ,  $w \in \Sigma^*$ ,  $\beta \in \Gamma^*$ ).

Relace  $\vdash_M^*$  (odvození v konečně mnoha krocích) je reflexivním a tranzitivním uzávěrem relace  $\vdash_M$ .

*Jazykem rozpoznávaným* (nebo též *přijímaným*) zásobníkovým automatem  $M$  rozumíme jazyk

$$L(M) = \{w \in \Sigma^* \mid (q_0, w, Z_0) \vdash_M^* (q, \varepsilon, \varepsilon) \text{ pro nějaký } q \in Q\}.$$

Připomněli jsme, že tedy jako základní bereme přijímání prázdným zásobníkem, a speciálně jsme zdůraznili, že jako základní verze se u zásobníkových automatů berou *nedeterministické* zásobníkové automaty.

Všimli jsme si, že náš výše sestrojený automat byl deterministický, což znamená

- $\delta(q, a, X)$  je vždy nejvýše jednoprvková množina (pro  $a \in \Sigma \cup \{\varepsilon\}$ ) (tedy neexistují dvě různé instrukce se stejnou levou stranou),
- je-li  $\delta(q, \varepsilon, X) \neq \emptyset$ , pak  $\delta(q, a, X) = \emptyset$  pro vš.  $a \in \Sigma$  (může-li automat udělat  $\varepsilon$ -krok, nemůže mu jiná instrukce zároveň umožňovat přečtení vstupního symbolu).

Pak jsme náš konkrétní ZA upravili tak, aby rozpoznával jazyk

$$L' = \{ww^R \mid w \in \{a, b\}^*\}$$

a uvědomili jsme si, že vzniklý automat už není deterministický. Uvedli jsme si, že  $L'$  nelze rozpoznat žádným deterministickým ZA, tedy že  $L'$  nepatří do třídy DCFL. (Intuitivně to není těžké nahlédnout, exaktní důkaz je ovšem komplikovaný.)

Pak jsme si uvedli větu

*Věta.* (Nedeterministické) zásobníkové automaty rozpoznávají právě bezkontextové jazyky, tedy jazyky z třídy CFL.

Ukažme ji v jednom směru (k bezkontextové gramatice  $G$  lze sestrojit [dokonce jen jednostavový] ZA  $M$  tak, že  $L(G) = L(M)$ ); ilustrujme na příkladu gramatiky

- 1/  $A \longrightarrow A + B$
- 2/  $A \longrightarrow B$
- 3/  $B \longrightarrow B * C$
- 4/  $B \longrightarrow C$
- 5/  $C \longrightarrow (A)$
- 6/  $C \longrightarrow a$

Použijeme obecný postup

Pro BG  $G = (\Pi, \Sigma, S, P)$  sestrojme  $M = (\{q_0\}, \Sigma, \Pi \cup \Sigma, \delta, q_0, S)$ , kde

pro  $X \in \Pi$ :  $\delta(q_0, \varepsilon, X) = \{(q_0, \alpha) \mid (X \rightarrow \alpha) \in P\}$

a pro  $a \in \Sigma$ :  $\delta(q_0, a, a) = \{(q_0, \varepsilon)\}$ .

(Všude jinde  $\delta$  přiřazuje  $\emptyset$ .)

Ilustrujme-li běh sestrojeného (‘velmi’ nedeterministického) ZA např. na slově  $a * (a + a)$ , všimneme si, že tento běh odpovídá konstrukci příslušného derivačního stromu metodou „shora dolů“.


## Vztah mezi přijímáním jazyka prázdným zásobníkem a přijímacími stavy

Načrtli jsme, proč v tom není zásadní rozdíl; třída přijímaných jazyků je v obou případech stejná (jedná se o třídu bezkontextových jazyků).

V případě nedeterministických automatů lze tyto verze mezi sebou snadno převádět, využitím přidaného speciálního symbolu na dně zásobníku. V případě deterministických zásobníkových automatů je vhodné brát jako základní verzi tu s přijímacími stavy; lze ji ovšem nahradit přijímáním prázdným zásobníkem, zakončíme-li každé vstupní slovo speciálním koncovým symbolem. (Tedy když  $L \subseteq \Sigma^*$  je přijímán DZA  $M$  s přijímacími stavy, tak jazyk  $L \cdot \{-\}$ , kde  $- \notin \Sigma$ , je přijímán DZA  $M'$  prázdným zásobníkem.)

## Hierarchie jazyků

Probrali jsme si načrtnutou hierarchii jazyků.



## Uzávěrové vlastnosti třídy CFL (tedy třídy bezkontextových jazyků)

Uvědomili jsme si, že snadno umíme ukázat, že CFL je uzavřena vůči sjednocení. Pohovořili jsme o dalších uzávěrových vlastnostech.

## Partie textu k prostudování

Části 4.1. - 4.4. (bezkontextové gramatiky), část 5.1. (speciální bezkontextové gramatiky). Zásobníkové automaty (část 4.5.) a jejich varianty. Uzávěrové vlastnosti CFL (část 5.2.).

(Máte si udělat přinejmenším dobrou první představu a zamyslet se nad příklady, speciálně těmi plánovanými na cvičení, ať se můžete na cvičení aktivně účastnit a případné problémy si tam objasnit.)

## Cvičení

### Příklad 6.1

Připomeňte si správný postup redukce gramatiky a proveďte jej na příkladu.

$$S \longrightarrow aBC \mid aCa \mid bBCa$$

$$B \longrightarrow bBa \mid bab \mid SS$$

$$C \longrightarrow BS \mid aCaa \mid bSSc$$

### Příklad 6.2

Pro bezkontextovou gramatiku  $G = (\Pi, \Sigma, S, P)$  definujte množinu všech neterminálů, z nichž lze odvodit prázdné slovo, tedy množinu  $\mathcal{E} = \{Z \in \Pi \mid Z \Rightarrow^* \varepsilon\}$ , induktivní definicí.  $\mathcal{E} \subseteq \Pi$  je tedy nejmenší množina splňující podmínky .... (podobně jako u obdobných definic v přednášce).

Na základě této induktivní definice navrhnete algoritmus konstruující  $\mathcal{E}$  a aplikujte jej na následující gramatiku  $G$ .

$$S \longrightarrow AB \mid \varepsilon$$

$$A \longrightarrow aAAb \mid BS \mid CA$$

$$B \longrightarrow BbA \mid CaC \mid \varepsilon$$

$$C \longrightarrow aBB \mid bS$$

Teď bychom chtěli zkonstruovat gramatiku  $G'$ , která nebude obsahovat tzv.  $\varepsilon$ -pravidla, tedy pravidla s pravou stranou  $\varepsilon$ , ale bude generovat stejný jazyk jako  $G$ , s případnou výjimkou  $\varepsilon$  (tedy  $L(G') = L(G) - \{\varepsilon\}$ ).

Můžeme prostě  $\varepsilon$ -pravidla z  $G$  vypustit a prohlásit výslednou gramatiku za kýženou  $G'$ ? Vysvětlete, proč ne; tedy ukažte (jednoduchý) případ, kdy tento postup nefunguje.

Zkuste přijít na (obecně platný) postup, jak  $G'$  sestrojít, když známe množinu  $\mathcal{E}$ . (Nápo-  
věda. Pravidlo s pravou stranou obsahující neterminály z  $\mathcal{E}$  je potřeba nahradit několika pravidly, v nichž jsou některé výskyty neterminálů z  $\mathcal{E}$  případně vypuštěny; musíme přitom zaručit, že nedojde k ztrátě možnosti odvození nějakého neprázdného slova.)

### Příklad 6.3

Domyslete podrobnosti převodu gramatiky do Chomského normální formy a aplikujte tento převod na následující gramatiku.

$$S \longrightarrow (E) \mid E$$

$$E \longrightarrow F + F \mid F \times F$$

$$F \longrightarrow a \mid S$$

**Příklad 6.4**

Promyslete si následující postup, který k bezkontextové gramatice  $G$  sestrojí jednostavový ZA  $M$  tak, že  $L(G) = L(M)$ :

Pro BG  $G = (\Pi, \Sigma, S, P)$  sestrojme  $M = (\{q_0\}, \Sigma, \Pi \cup \Sigma, \delta, q_0, S)$ , kde

pro  $X \in \Pi$ :  $\delta(q_0, \varepsilon, X) = \{(q_0, \alpha) \mid (X \rightarrow \alpha) \in P\}$

a pro  $a \in \Sigma$ :  $\delta(q_0, a, a) = \{(q_0, \varepsilon)\}$ .

(Všude jinde  $\delta$  přiřazuje  $\emptyset$ .)

Aplikujte jej na příkladu gramatiky

1/  $A \rightarrow A + B$

2/  $A \rightarrow B$

3/  $B \rightarrow B * C$

4/  $B \rightarrow C$

5/  $C \rightarrow (A)$

6/  $C \rightarrow a$

Ilustrujte úspěšný běh sestrojeného (‘velmi’ nedeterministického) ZA např. na slově  $a * (a + a)$ ;

konstruujte tedy posloupnost konfigurací

$$(q_0, a * (a + a), A) \vdash (q_0, a * (a + a), B) \vdash (q_0, a * (a + a), B * C) \vdash (q_0, a * (a + a), C * C) \vdash (q_0, a * (a + a), a * C) \vdash (q_0, *(a + a), *C) \vdash (q_0, (a + a), C) \vdash \dots \vdash (q_0, \varepsilon, \varepsilon)$$

a všimněte si, že tento běh odpovídá konstrukci příslušného derivačního stromu metodou „shora dolů“.

**Příklad 6.5**

V jednom dřívějším příkladu jste zkonstruovali gramatiku generující jazyk

$$L = \{w \in \{a, b\}^* \mid |w| \geq 1 \text{ a } |w|_a = |w|_b\}.$$

Připomeňte si ji a pak na ni aplikujte obecný postup, který k bezkontextové gramatice sestrojí ekvivalentní (jednostavový) zásobníkový automat (realizující metodu shora dolů). Takto sestrojíte (nedeterministický) ZA  $M$ .

Pak zkuste (co nejefektivnější) přímý návrh ZA  $M'$ . Podaří se vám navrhnout  $M'$  deterministický? Jestli ano, podaří se vám takový deterministický automat s jedním stavem?

**Příklad 6.6**

Připomeňte si, co to znamená, že CFL (třída bezkontextových jazyků) je uzavřena vůči sjednocení, zřetězení, iteraci a zrcadlovému obrazu. Pak toto prokažte (jednoduchými konstrukcemi, které např. k dvěma gramatikám  $G_1, G_2$  sestrojíte gramatiku  $G$  tž.  $L(G) = L(G_1) \cup L(G_2)$ , atd.).

(Nápověda pro zrcadlový obraz: připomeňte si, že  $(L_1 \cdot L_2 \cdot \dots \cdot L_m)^R = (L_m)^R \cdot (L_{m-1})^R \cdot \dots \cdot (L_1)^R$ .)

**Příklad 6.7**

Prokažte, že CFL je uzavřena vůči průniku s regulárním jazykem, tedy, že pro každý bezkontextový jazyk  $L$  a každý regulární jazyk  $R$  platí, že  $L \cap R$  je bezkontextový. (Využijte charakterizaci CFL pomocí zásobníkových automatů a vzpomeňte si na konstrukci automatu pro průnik dvou jazyků zadaných konečnými automaty.)