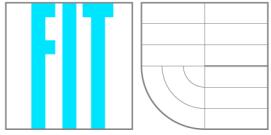
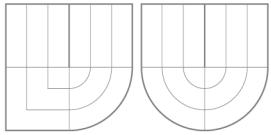


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ  
ÚSTAV INFORMAČNÍCH SYSTÉMŮ  
FACULTY OF INFORMATION TECHNOLOGY  
DEPARTMENT OF INFORMATION SYSTEMS

# SYNTAKTICKÁ ANALÝZA ZALOŽENÁ NA REGULOVANÝCH AUTOMATECH

PARSING BASED ON REGULATED AUTOMATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

ĽUBICA GENČÚROVÁ

VEDOUCÍ PRÁCE

SUPERVISOR

Prof. RNDr. ALEXANDER MEDUNA, CSc.

BRNO 2016

## Zadání bakalářské práce

Řešitel: **Genčúrová Ľubica**

Obor: Informační technologie

Téma: **Syntaktická analýza založená na regulovaných automatech**  
**Parsing Based on Regulated Automata**

Kategorie: Překladače

### Pokyny:

1. Dle pokynů vedoucího se seznamte detailně s regulovanými automaty a jejich vlastnostmi.
2. Dle pokynů vedoucího studujte nové vlastnosti těchto automatů.
3. Navrhněte jednoduchou metodu syntaktické analýzy, která je založena na automatech s hlubokými zásobníky.
4. Studujte užití metody syntaktické analýzy navržené v předchozích bodech. Zaměřte se na překladače programovacích jazyků. Navrhněte vhodný programovací jazyk a sestrojte jeho syntaktický analyzátor, který provádí syntaktickou analýzu na základě této metody. Testujte výsledný syntaktický analyzátor.
5. Zhodnotte dosažené výsledky a diskutujte další možný vývoj projektu.

### Literatura:

- Meduna, A.: Automata and Languages, Springer, London, 2000

Pro udělení zápočtu za první semestr je požadováno:

- Splnění prvních 3 bodů zadání.

Podrobné závazné pokyny pro vypracování bakalářské práce naleznete na adrese  
<http://www.fit.vutbr.cz/info/szz/>

Technická zpráva bakalářské práce musí obsahovat formulaci cíle, charakteristiku současného stavu, teoretická a odborná východiska řešených problémů a specifikaci etap (20 až 30% celkového rozsahu technické zprávy).

Student odevzdá v jednom výtisku technickou zprávu a v elektronické podobě zdrojový text technické zprávy, úplnou programovou dokumentaci a zdrojové texty programů. Informace v elektronické podobě budou uloženy na standardním nepřepisovatelném paměťovém médiu (CD-R, DVD-R, apod.), které bude vloženo do písemné zprávy tak, aby nemohlo dojít k jeho ztrátě při běžné manipulaci.

Vedoucí: **Meduna Alexander, prof. RNDr., CSc., UIFS FIT VUT**

Datum zadání: 1. listopadu 2015

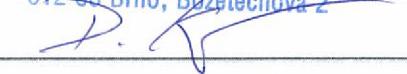
Datum odevzdání: 18. května 2016

**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

Fakulta informačních technologií

Ústav informačních systémů

612 66 Brno, Božetěchova 2



doc. Dr. Ing. Dušan Kolář  
vedoucí ústavu

## **Abstrakt**

Tato práce se zabývá návrhem, aplikovatelností v praxi a implementací metody syntaktické analýzy založené na zásobníkových automatech, které regulují použití jejich pravidel řídícím lineárním jazykem. Tyto automaty mají větší sílu než běžný zásobníkový automat a jejich síla je rovna Turingovému stroji. Jsou schopné akceptovat rodinu rekurzivně vyčíslitelných jazyků.

## **Abstract**

This work deals with the design, applicability and the implementation of parsing methods based on pushdown automata that regulate the use of their rules by linear control languages. These automata are more powerful than ordinary automata and they are as powerful as Turing machine. The pushdown automata regulated by linear control languages characterize the family of recursively enumerable languages.

## **Klíčová slova**

Regulované automaty, zásobníkové automaty, řídící jazyk, lineární jazyk, rekurzivně vyčíslitelný jazyk, syntaktická analýza

## **Keywords**

Regulated automata, pushdown automata, control language, linear language, recursively enumerable languages, parsing

## **Citace**

GENČÚROVÁ, Lubica. *Syntaktická analýza založená na regulovaných automatech*. Brno, 2016. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Meduna Alexander.

# Syntaktická analýza založená na regulovaných automatech

## Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně pod vedením pana Prof. RNDr. Alexandra Meduny, CSc. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.

.....  
Ľubica Genčúrová  
17. května 2016

## Poděkování

Ráda bych poděkovala panu Prof. RNDr. Alexanderovi Medunovu, CSc. za kontrolu mých textů, jeho ochotu a odborné rady na konzultacích a v neposlední řadě také za pomoc při výběru tématu mé práce.

© Ľubica Genčúrová, 2016.

*Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.*

# Obsah

<b>1</b>	<b>Úvod</b>	<b>4</b>
<b>2</b>	<b>Úvod do teórie formálnych jazykov</b>	<b>6</b>
2.1	Abecedy a reťazce . . . . .	6
2.2	Jazyky . . . . .	6
<b>3</b>	<b>Gramatiky</b>	<b>8</b>
3.1	Chomského klasifikácia gramatík . . . . .	9
3.1.1	Typ 0 - Frázová gramatika . . . . .	9
3.1.2	Typ 1 - Kontextová gramatika . . . . .	9
3.1.3	Typ 2 - Bezkontextová gramatika . . . . .	10
3.1.4	Typ 3 - Regulárna gramatika . . . . .	10
3.1.5	Lineárna gramatika . . . . .	11
3.2	Frontové gramatiky . . . . .	11
3.2.1	Ľavo-rozšírená frontová gramatika . . . . .	12
<b>4</b>	<b>Automaty</b>	<b>13</b>
4.1	Konečný automat . . . . .	13
4.2	Zásobníkové automaty . . . . .	14
<b>5</b>	<b>Regulované automaty</b>	<b>16</b>
5.1	Zásobníkové automaty regulované riadiacim jazykom . . . . .	16
5.2	Zásobníkové automaty regulované lineárnym riadiacim jazykom . . . . .	18
5.2.1	Jedno-otáčkový atomický zásobníkový automat regulovaný lineárnym jazykom . . . . .	20
<b>6</b>	<b>Syntaktická analýza v prekladačoch</b>	<b>22</b>
<b>7</b>	<b>Zstrojenie syntaktického analyzátora</b>	<b>25</b>
7.1	Generovanie reťazca rekurzívne vyčísliteľného jazyka . . . . .	25
7.2	Zstrojenie automatu regulovaného riadiacim lineárnym jazykom . . . . .	26
<b>8</b>	<b>Implementácia</b>	<b>29</b>
8.1	Simulácia frázovej gramatiky . . . . .	29
8.2	Syntaktická analýza založená na regulovanom zásobníkovom automate . . . . .	31
<b>9</b>	<b>Záver</b>	<b>34</b>
	<b>Literatúra</b>	<b>36</b>

<b>Prílohy</b>	<b>37</b>
Zoznam príloh . . . . .	38
<b>A Obsah CD</b>	<b>39</b>
<b>B Demonštrácia programu</b>	<b>40</b>
<b>C Manuál</b>	<b>45</b>

# Zoznam obrázkov

3.1	Chomského hierarchia . . . . .	9
3.2	Vzťahy množín ľavo-rozsírenej frontovej gramatiky . . . . .	12
4.1	Zásobníkový automat . . . . .	14
5.1	Jedno-otáčkový zásobníkový automat . . . . .	20
6.1	Prekladač . . . . .	23
6.2	Lexikálna analýza - rozoznanie lexikálnych jednotiek v zdrojovm kóde . . . . .	24
6.3	Vytváranie derivačného stromu . . . . .	24
B.1	Generovanie reťazca, ktorý je vhodný ako vstup pre parser . . . . .	41
B.2	Reťazec generovaný jednou lineárnu gramatikou . . . . .	42
B.3	Akceptovanie reťazca, ktorý je syntakticky správny . . . . .	43
B.4	Akceptovanie reťazca, ktorý nie je syntakticky správny . . . . .	44

# Kapitola 1

## Úvod

Táto práca sa zaobrá návrhom, aplikovateľnosťou a implementáciou jednoduchej metódy syntaktickej analýzy, ktorá je založená na zásobníkových automatoch regulovaných riadiacim lineárnym jazykom. Poukazuje na významný efekt a zvýšenie výpočetnej sily zásobníkového automatu vďaka použitiu kontrolného jazyka pre regulovanie automatu.

Pre pochopenie jadra tejto bakalárskej práce, teda popis, zstrojenie tohto typu automatu a následne zstrojenie syntaktickej analýzy na základe tejto metódy, je potrebné sa zoznámiť s teóriou formálnych jazykov.

Základy teórie formálnych jazykov položil v roku 1956 americký matematik Noam Chomský, ktorý pri štúdiu prirodzených jazykov vytvoril matematický model gramatiky jazyka. Pôvodná predstava bola vytvoriť formálny popis prirodzeného jazyka, vďaka ktorému by bolo možné vykonávať automatizovaný preklad medzi prirodzenými jazykmi alebo komunikovať pomocou prirodzeného jazyka s počítačom. Kedže realizácia tejto predstavy bola obtiažna, začala sa vyuvíjať teória formálnych jazykov, ktorá našla najväčšie uplatnenie v oblasti programovacích jazykov pre definíciu syntaxe programovacieho jazyka.

Konečné jazyky sa dajú jednoducho popísť vymenovaním všetkých slov, ale táto špecifikácia nie je možná pre väčšinu programovacích jazykov, pretože patria medzi nekonečné jazyky. Preto potrebujeme pre špecifikáciu formálnych jazykov konečné prostriedky. Vhodnými prostriedkami pre konečnú reprezentáciu programovacích jazykov sú gramatiky a automaty. Gramatika popisuje štruktúru viet formálneho jazyka a automat dokáže túto štruktúru ľahko identifikovať a spracovať.

V posledných desaťročiach hrali dôležitú rolu v teórii formálnych jazykov gramatiky, ktoré regulujú používanie svojich pravidiel rôznymi kontrolnými mechanizmami. Okrem gramatík, ale teória formálnych jazykov využíva ako základné jazykové modely automaty. Práve vďaka týmto skutočnostiam vznikla myšlienka zaviesť zásobníkové automaty regulujúce použitie pravidla riadiacim jazykom. Tieto automaty boli prvý krát predstavené v roku 2000, v článku *Regulated Pushdown Automata* [2].

Ako riadiaci jazyk bol spočiatku skúmaný regulárny, avšak táto regulácia nemá žiadny efekt na výpočetnú silu zásobníkového automatu. Ak je zvolený ako riadiaci jazyk lineárny, automaty sú schopné prijímať rodinu rekurzívne vyčísliteľných jazykov. Ich výpočetná sila je väčšia ako sila bežných zásobníkových automatov a zároveň zrovnatelná so silou Turingovho stroja. Kedže automatom tohto typu nebola od vydania článku venovaná pozornosť, bolo mojom motiváciou zamerať sa práve na ne a pokúsiť sa o aplikáciu v praxi.

V nasledujúcej kapitole 2 nájdeme stručný úvod do problematiky formálnych jazykov a základné definície potrebné pre ďalšie kapitoly. V kapitole 3 a 4 si už následne definujeme konkrétnie prostriedky pre reprezentáciu a rozpoznávanie jazyka, aby sme sa priblížili k cieľu

tejto práce, a mohli sme predstaviť regulované automaty v kapitole 5. Popis syntaktickej analýzy a jej využitia nájdeme v kapitole 6.

Zvyšná časť bakalárskej práce sa venuje praktickej časti, kde sa nachádza formálne zostrojenie syntaktického analyzátora a konkrétnych entít potrebných pre činnosť syntaktickej analýzy. Tento celok je členený na dve časti.

Prvá časť slúži pre generovanie reťazca rekurzívne vyčísliteľného jazyka. Ako bude z nasledujúcich kapitol zrejmé, tento jazyk je generovaný frázovou gramatikou, taktiež nazývanou ako neobmedzená gramatika. Práve preto je v praxi veľmi ťažko implementovateľná. Jej činnosť je v tejto práci simulovaná dvomi regulovanými lineárnymi gramatikami.

Druhá časť je zameraná na akceptovanie toho reťazca syntaktickou analýzou založenou na zásobníkovom automate, ktorý reguluje použitie pravidiel lineárnym riadiacim jazykom. Riadiaci jazyk je generovaný lineárhou gramatikou.

Na záver sú uvedené podrobnosti implementácie a v prílohách sa nachádza demonštrácia implementovanej metódy.

## Kapitola 2

# Úvod do teórie formálnych jazykov

Na úvod si definujeme základné matematické pojmy, ktoré sú dôležité pre popis formálnych jazykov a pochopenie nasledujúcich kapitol. Definície sú prebrané zo zdrojov [1] a [3].

### 2.1 Abecedy a reťazce

**Definícia 2.1.1.** *Abeceda* je ľubovoľná konečná neprázdna množina elementov, ktoré nazývame *symboly*. Sekvencia symbolov tvorí reťazec.

**Definícia 2.1.2.** Majme abecedu  $\Sigma$ . Ak  $\varepsilon$  je reťazec nad  $\Sigma$  a symbol  $a \in \Sigma$ , potom  $xa$  je reťazec nad abecedou  $\Sigma$ .

**Definícia 2.1.3.** Majme reťazec  $x$  nad abecedou  $\Sigma$ . Dĺžka reťazca  $x$ ,  $|x|$  je definovaná nasledovne.

Ak  $x = \varepsilon$ , potom  $|x| = 0$ .

Ak  $x = a_1 \dots a_n$ , pre  $n \geq 1$ , kde  $a_i \in \Sigma$  pre všetky  $i = 1, \dots, n$ , platí  $|x| = n$ .

### Operácie nad reťazcami

Stručne si predstavíme základné operácie nad reťazcami.

**Definícia 2.1.4.** Majme dva reťazce  $x$  a  $y$  nad abecedou  $\Sigma$ .

- Potom  $xy$  je *konkatenácia* týchto dvoch reťazcov. Pre každý reťazec  $x$  platí:  
 $x\varepsilon = \varepsilon x = x$ .
- Ak existuje slovo  $z$  nad abecedou  $\Sigma$  a  $xz = y$ , tak  $x$  je *prefix* reťazca  $y$ ,  $\text{prefix}(x) \in y$
- Ak existuje slovo  $z$  nad abecedou  $\Sigma$  a  $zx = y$ , tak  $x$  je *sufix* reťazca  $y$ ,  $\text{sufix}(x) \in y$
- Ak existujú dve slová  $z$  a  $z'$  nad abecedou  $\Sigma$  a  $zxz' = y$ , tak  $x$  je *podreťazec* reťazca  $y$

### 2.2 Jazyky

Jazyky sú matematicky definované ako sekvencie pozostávajúce zo symbolov.

**Definícia 2.2.1.** Uvažujme abecedu  $\Sigma$ . Nech  $\Sigma^*$  značí množinu všetkých reťazcov nad  $\Sigma$ . Každá podmnožina  $L \subseteq \Sigma^*$  je jazyk nad  $\Sigma$ . Množina  $\Sigma^+$  značí množinu  $\Sigma^* - \{\varepsilon\}$ ,  $\Sigma^+ = \Sigma^* - \varepsilon$ .

**Definícia 2.2.2.** Jazyk  $L$  je *konečný*, ak  $L$  obsahuje konečný počet reťazcov, teda  $\text{card}(L) = n$  a  $n \geq 0$ ; inak je *nekonečný*.

## Operácie nad jazykmi

Stručne si predstavíme základné operácie nad jazykmi.

**Definícia 2.2.3.** Nech sú  $L, L_1$  a  $L_2$  jazyky nad abecedou  $\Sigma$ .

- *Zjednotenie jazykov*  $L_1$  a  $L_2$ ,  $L_1 \cup L_2$  je definované ako:  $L_1 \cup L_2 = \{x : x \in L_1 \text{ alebo } x \in L_2\}$ .
- *Priek*  $L_1$  a  $L_2$ ,  $L_1 \cap L_2$  je definovaný ako:  $L_1 \cap L_2 = \{x : x \in L_1 \text{ a } x \in L_2\}$ .
- *Rozdiel jazykov*  $L_1$  a  $L_2$ ,  $L_1 - L_2$  je definovaný ako:  $L_1 - L_2 = \{x : x \in L_1 \text{ a } x \notin L_2\}$ .
- *Doplňok jazyka*  $L, \overline{L}$ , je definovaný ako:  $\overline{L} = \Sigma^* - L$ .
- *Konkatenácia jazykov*  $L_1$  a  $L_2$ ,  $L_1 L_2$  je definovaná ako:  $L_1 L_2 = \{xy : x \in L_1 \text{ a } y \in L_2\}$ . Každý jazyk spĺňa podľa tejto definície nasledujúce dve vlastnosti:
  1.  $L\{\varepsilon\} = \{\varepsilon\}L = L$
  2.  $L\emptyset = \emptyset L = L$
- *Reverzia jazyka*  $L$ ,  $\text{reverse}(L)$  je definovaná ako:  $\text{reverse}(L) = \{\text{reverse}(x) : x \in L\}$ .
- *Iterácia jazyka*  $L$ ,  $L^i$  je definovaná:
  1.  $L^0 = \{\varepsilon\}$
  2. pre  $i \geq 1$ :  $L^i = LL^{i-1}$
- Pre  $i \geq 0$ ,  $i$ -tá mocnina jazyka  $L$ ,  $L^*$ , a *Pozitívna iterácia jazyka*  $L$ ,  $L^+$ , sú definované:

$$L^* = \bigcup_{i=0}^{\infty} L^i \text{ a } L^+ = \bigcup_{i=1}^{\infty} L^i$$

Podľa týchto definícií má každý jazyk tieto dve vlastnosti:

1.  $L^+ = LL^* = L^*L$
2.  $L^* = L^* \cup \{\varepsilon\}$

# Kapitola 3

## Gramatiky

Triviálny spôsob reprezentácie jazyka, akým je vymenovanie všetkých viet jazyka, je ne-použiteľný pre reprezentáciu nekonečného jazyka. Dokonca je obtiažne reprezentovať týmto spôsobom rozsiahle konečné jazyky, preto využívame formálne prostriedky pre reprezentáciu jazykov.

Najznámejším prostriedkom pre reprezentáciu jazyka je gramatika. Gramatiky zohrávajú hlavnú rolu v teórii formálnych jazykov a splňajú základnú požiadavku kladenú na reprezentáciu konečných aj nekonečných jazykov - požiadavka konečnosti reprezentácie.

Gramatika využíva dve konečné abecedy (2.1.1), ktoré sú navzájom disjunktné:

1. množina  $N$  - *nonterminálnych symbolov*, skrátene *nonterminály*, sú pomocné pre-menné, ktoré označujú určité syntaktické celky.
2. množina  $T$  - *terminálnych symbolov*, skrátene *terminály*. Množina *terminálov* je iden-tická s abecedou, nad ktorou je definovaný jazyk.

Gramatika je zariadenie, ktoré generuje jazyk. Z *nonterminálu* aplikáciou prepisovacieho pravidla generuje reťazce - vetté formy, ktoré sú tvorené *terminálmi* a *neterminálmi*. Vetté formy, ktoré obsahujú len terminály, reprezentujú vety gramatikou definovaného jazyka. Ak gramatika negeneruje žiadnu vetu, reprezentuje prázdný jazyk.

Jadrom gramatiky je konečná množina *prepisovacích pravidiel* (skrátene *pravidlá*). Po-dľa tvaru týchto pravidiel klasifikujeme gramatiky do jednotlivých tried.

V roku 1956 americký matematik Noam Chomský zaviedol *Chomského klasifikáciu gra-matík a jazykov*. Rozdelil formálne gramatiky a nimi definované jazyky na štyri základné typy gramatík, podľa ich vyjadrovacej schopnosti. Tieto typy gramatík sa označujú ako typ 0, typ 1, typ 2 a typ 3.

Definícia týchto gramatík má rovnaký základ. Odlišuje sa iba v tvare prepisovacích pravidiel.

**Definícia 3.0.1.** Frázová gramatika je štvorica  $G = (N, T, P, S)$ , kde

- $N$  je abeceda *neterminálov*;
- $T$  je abeceda *terminálov*, kde  $N \cap T = \emptyset$ ;
- $P$  je konečná množina *pravidiel*;
- $S \in N$  je počiatočný symbol gramatiky.

Pravidlá sú usporiadane dvojice  $(u, v) \in P$ , ktoré sa nazývajú *prepisovacie pravidlá* alebo *produkcie* a majú tvar  $u \rightarrow v$ . Pravidlo určuje možnú substitúciu reťazca  $u$  za reťazec  $v$ . Reťazec  $u$  obsahuje vždy aspoň jeden *nonterminál*. Reťazec  $v$  je prvkom množiny  $(N \cup T)^*$ . Formálne:

$$P \subseteq (N \cup T)^* N (N \cup T)^* \times (N \cup T)^*$$

Ak  $v$  je prázdný reťazec, teda  $v = \epsilon$ , toto pravidlo nazývame  $\epsilon$ -pravidlo.

Množina  $V = N \cup T$  je *úplna abeceda* gramatiky  $G$ .

### 3.1 Chomského klasifikácia gramatík

Chomského klasifikácia gramatík je taktiež známa pod názvom Chomského hierarchia jazykov. Táto hierarchia rozdeľuje formálne jazyky a gramatiky na štyri základné typy.

Hierarchickosť gramatík spočíva v tom, že gramatiky vyššieho typu je možné klasifikovať akýmkoľvek nižším typom (viď. obrázok 3.1). Napríklad gramatika typu 2 je zároveň gramatikou typu 1 a 0.

Ako už bolo spomenuté všetky triedy gramatík majú rovnaký základ. Uvažujme teda gramatiku  $G$  z definície 3.0.1. Potom prepisovacie pravidlá z množiny prepisovacích pravidiel  $P$  budú vyzerať nasledovne:

#### 3.1.1 Typ 0 - Frázová gramatika

Gramatika typu 0 obsahuje pravidlá v najväčšom tvare, zhodným s definíciou 3.0.1 gramatiky:

$$\begin{aligned} & u \rightarrow v, \text{ kde} \\ & u \in (N \cup T)^* N (N \cup T)^*, v \in (N \cup T)^* \end{aligned}$$

Nazýva sa taktiež aj *neobmedzená*. Generuje jazyky akceptovateľné Turingovým strojom<sup>1</sup>, nazývané ako *rekurzívne vyčísliteľné jazyky*. Rodina týchto jazykov je označovaná ako **RE** (Recursively enumerable).

#### 3.1.2 Typ 1 - Kontextová gramatika

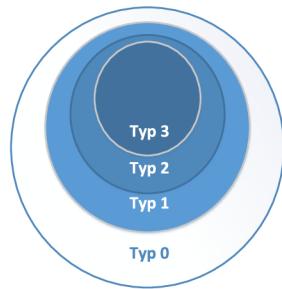
Gramatika typu 1 obsahuje pravidlá tvaru:

$$\begin{aligned} & u \rightarrow v, \text{ kde} \\ & u = x_1 A x_2, v = x_1 y x_2 \text{ a } A \in N, x_1, x_2 \in (N \cup T)^*, y \in (N \cup T)^+ \end{aligned}$$

Pravidlá kontextovej gramatiky sú obmedzené dĺžkou reťazca. musí platiť, že dĺžka pravidla na pravej strane je rovná alebo väčšia ako dĺžka pravidla na ľavej strane.

---

<sup>1</sup>Turingov stroj je zložený z konečného automatu, pravidiel prechodovej funkcie a teoreticky nekonečnej pásky.



Obr. 3.1: Chomského hierarchia

Výnimku tvorí pravidlo:

$S \rightarrow \epsilon$ , pokiaľ sa  $S$  nevyskytuje na pravej strane žiadneho pravidla.

Táto gramatika generuje *kontextové jazyky*, ktoré akceptuje lineárne ohraničený konečný automat<sup>2</sup>. Rodina *kontextových jazykov* je označovaná ako **CS** (context-sensitive).

### 3.1.3 Typ 2 - Bezkontextová gramatika

Gramatika typu 2 obsahuje pravidlá tvaru:

$$\begin{aligned} A &\rightarrow x, \text{ kde} \\ A &\in N, x \in (N \cup T)^* \end{aligned}$$

Výnimku tvorí opäť prepisovacie pravidlo:

$S \rightarrow \epsilon$ , pokiaľ sa  $S$  nevyskytuje na pravej strane žiadneho pravidla.

Na ľavej strane pravidla je povolený iba jeden neterminál. Touto gramatikou sú generované *bezkontextové jazyky*, ktoré sú akceptovateľné zásobníkovým automatom (4.2.1). Rodina *bezkontextových jazykov* je označovaná ako **CF** (context-free).

### 3.1.4 Typ 3 - Regulárna gramatika

**Definícia 3.1.1.** Gramatika typu 3 obsahuje pravidlá tvaru:

$$\begin{aligned} A &\rightarrow aB \text{ alebo } A \rightarrow a, \text{ kde} \\ A, B &\in N, a \in T \end{aligned}$$

Ako v prípade gramatík typu 1 a 2 výnimku tvorí prepisovacie pravidlo:

$S \rightarrow \epsilon$ , pokiaľ sa  $S$  nevyskytuje na pravej strane žiadneho pravidla.

Regulárna gramatika generuje *regulárne jazyky*. Tieto jazyky akceptuje konečný automat (4.1.1). Rodina *regulárnych jazykov* je označovaná ako **REG** (regular).

Alternatívne je rodina regulárnych jazykov charakterizovaná *pravou lineárnu gramatikou*. Prepisovacie pravidlá tejto gramatiky majú tvar:

$$\begin{aligned} A &\rightarrow xB \text{ alebo } A \rightarrow x, \text{ kde} \\ A, B &\in N, x \in T^* \end{aligned}$$

Pravá lineárna gramatika generuje *pravé lineárne jazyky*. Rodina týchto jazykov je označovaná ako **RLIN** (right-linear).

V praxi sa používajú hlavne gramatiky typu 2 - bezkontextové a typu 3 - regulárne. Do skupiny bezkontextových jazykov patria programovacie jazyky, pre ktoré v každom prekladači existuje syntaktický analyzátor.

Okrem týchto základných typov gramatík existujú i iné. Všetky gramatiky, ktoré generujú rekurzívne vyčísliteľné jazyky je možné zaradiť do Chomského hierarchie. Týmto zaradením získame odhad ich sily vzhľadom na tieto štyri typy gramatík.

Pre pochopenie nasledujúceho textu si uvedieme *Lineárnu gramatiku*, ktorú môžeme zaradiť v Chomského hierarchii medzi bezkontextovú a regulárnu gramatiku.

---

<sup>2</sup>Lineárne ohraničený konečný automat je obmedzená verzia Turingovho stroja s konečnou páskou, ktorej dĺžka je lineárne závislá na dĺžke vstupného reťazca.

### 3.1.5 Lineárna gramatika

**Definícia 3.1.2.** Uvažujme gramatiku  $G = (N, T, P, S)$  z definicie 3.0.1. Gramatika  $G$  je lineárna, ak každé pravidlo v množine  $P$  má nasledujúci tvar:

$$A \rightarrow xBy \text{ alebo } A \rightarrow x, \text{ kde} \\ A, B \in N \text{ a } x, y \in T^*$$

Toto gramatikou sú generované *lineárne jazyky*, ktoré sú akceptovateľné zásobníkovým automatom (4.2.1). Rodina *lineárnych jazykov* je označovaná ako **LIN** (linear).

Podľa Chomského hierarchie platí nasledujúci vzťah jazykov, ktoré sú generované gramatikami uvedenými v tejto sekcii:

$$REG = RLIN \subset LIN \subset CF \subset CS \subset RE$$

## 3.2 Frontové gramatiky

Frontové gramatiky prepíšu reťazec spôsobom, ktorý sa podobá na štandardnú abstraktnú dátovú štruktúru - frontu.

Tieto gramatiky pracujú na princípe **first-in-first-out**, teda prvý dnu, prvý von. Prvý symbol, ktorý bol pridaný do reťazca bude prvý odstránený.

Konkrétnie počas každého derivačného kroku gramatika pripojí reťazec ako sufíx - príponu, k aktuálnej vetnej forme a zároveň odstráni najľavejší symbol tejto formy. To znamená, že všetky symboly, ktoré boli pripojené k vetnej forme pred týmto krokom, musia byť odstránené skorej ako novopripojený sufíx.

**Definícia 3.2.1.** Frontová gramatika je šestica:  $Q = (V, T, W, F, R, g)$ , kde  $V$  a  $W$  sú dve abecedy, pre ktoré platí  $V \cap W = \emptyset, T \subset V, F \subset W, g \in (V - T)(W - F)$ , a

$$R \subseteq V \times (W - F) \times V^* \times W$$

je konečná relácia. Pre každé  $a \in V$  existuje element  $(a, b, x, c) \in R$ . Ak  $u = arb, v = rxc, a (a, b, x, c) \in R, r, x \in V^*$ , kde  $a \in V$  a  $b, c \in W$ , potom  $Q$  urobí *derivačný krok* z  $u$  do  $v$  podľa  $(a, b, x, c)$ . Symbolický zápis:

$$u \Rightarrow_Q v[(a, b, x, c)]$$

Zjednodušene:

$$u \Rightarrow_Q v$$

Jazyk gramatiky  $Q$  sa označuje ako  $L(Q)$  a je definovaný ako:

$$L(Q) = \{x \in T^* \mid g \Rightarrow_Q^* xf, f \in F\}$$

### 3.2.1 Ľavo-rozšírená frontová gramatika

**Definícia 3.2.2.** *Ľavo-rozšírená frontová gramatika*<sup>3</sup> je šestica:  $Q = (V, T, W, F, R, g)$ , kde  $V, T, W, F, R, g$  majú rovnaký význam, ako vo frontovej gramatike. S výnimkou, že platí  $\# \notin V \cup W$ . Ak  $u, v \in V^*\{\#\}V^*W$  tak  $u = w\#arb$ ,  $v = wa\#rzc$ ,  $a \in V$ ,  $r, z, w \in V^*$ ,  $b, c \in W$ , a  $(a, b, z, c) \in R$ , potom:

$$u \Rightarrow_Q v[(a, b, z, c)]$$

Jazyk gramatiky  $Q$  sa označuje ako  $L(Q)$  a je definovaný ako:

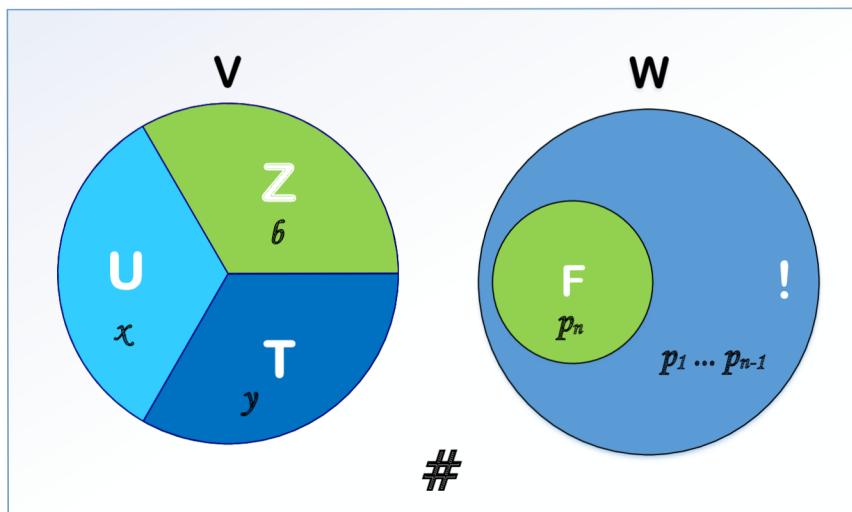
$$L(Q) = \{v \in T^* \mid \#g \Rightarrow_Q^* w\#fv \text{ pre } w \in V^* \text{ a } f \in F\}$$

Neformálne. Počas každého derivačného kroku, ľavo rozšírená frontová gramatika posúnie prepisovaný symbol nad  $\#$ . Toto zaznamenáva história derivácií.

Pre každú ľavo-rozšírenú frontovú gramatiku  $K$  existuje ľavo-rozšírená frontová gramatika  $Q = (V, T, W, F, s, P)$ , splňujúca  $L(K) = L(Q)$ ,  $!$  je rozlišujúci člen rozdielu množín  $(W - F)$ ,  $V = U \cup Z \cup T$ .  $U, Z, T$  sú navzájom disjunktné (pre lepšiu predstavu vzťahov množín pozri obrázok 3.2) a  $Q$  deriuje každé  $z \in L(Q)$  nasledovne:

$$\begin{aligned} S\# &\Rightarrow^+ x\#b_1b_2\dots b_n! \\ &\Rightarrow xb_1\#b_2\dots b_ny_1p_2 \\ &\Rightarrow xb_1b_2\#b_3\dots b_ny_1y_2p_3 \\ &\vdots \\ &\Rightarrow xb_1b_2\dots b_{n-1}\#\dots b_ny_1y_2\dots y_{n-1}p_n \\ &\Rightarrow xb_1b_2\dots b_{n-1}b_n\#y_1y_2\dots y_np_{n+1} \end{aligned}$$

kde  $n \in \mathcal{N}$ ,  $x \in U^*$ ,  $b_i \in Z$  pre  $i = 1, \dots, n$ ,  $y_i \in T^*$  pre  $i = 1, \dots, n$ ,  $z = y_1y_2\dots y_n$ ,  $p_i \in W - \{!\}$  pre  $i = 1, \dots, n-1$ ,  $p_n \in F$ , a iba derivácia  $x\#b_1b_2\dots b_n!$  obsahuje reťazec  $!$ . Dôkaz tohto tvrdenia sa nachádza v článku [2] v sekcii 4, Lemma 3.



Obr. 3.2: Vzťahy množín ľavo-rozšírenej frontovej gramatiky

<sup>3</sup>Anglicky Left-extended queue grammar

# Kapitola 4

## Automaty

V tejto sekcií si predstavíme jednoduché zariadenie, ktoré slúži na rozpoznávanie reťazcov, daných jazykom. V informatike sa najviac využívajú regulárne a bezkontextové jazyky. V predchádzajúcej kapitole 3.1, strana 9, sme spomenuli, že tieto jazyky prijíma *konečný automat* (REG) a *zásobníkový automat* (CF).

### 4.1 Konečný automat

Predstavíme si najjednoduchší model založený na konečnej množine stavov a výpočetných pravidiel. Tento model číta dané slovo nad vstupnou abecedou zľava doprava, symbol po symbol. Na začiatku sa nachádza v počiatočnom stave.

**Definícia 4.1.1.** *Konečný automat*<sup>1</sup> je pätnica  $M = (Q, \Sigma, R, s, F)$ , kde

- $Q$  je konečná množina *stavov*,
- $\Sigma$  je *vstupná abeceda*,
- $R \subseteq Q \times \Sigma^* \times Q$  je konečná množina *pravidiel*.
- $s \in Q$  je *počiatočný stav*,
- $F \subseteq Q$  je množina *koncových stavov*.

Namiesto relačného zápisu  $(p, y, q) \in R$ , zapisujeme pravidlá  $py \rightarrow q \in R$ . Ak  $R$  implikuje, že  $y \neq \varepsilon$ , tak tento automat je bez  $\varepsilon$ -prechodov.

Pravidlo  $py \rightarrow q \in R$  znamená, že pri prečítaní vstupného symbolu  $y$  automat  $M$  urobí *prechod* z  $p$  do  $q$ . Ak  $y = \varepsilon$ , tak sa zo vstupnej pásky neprečíta žiadny symbol.

**Definícia 4.1.2.**

*Konfigurácia* konečného automatu  $M$  (4.1.1) je reťazec  $\chi \in Q\Sigma^*$ . Nech  $\chi_1 = pax$  a  $\chi_2 = qx$  sú dve konfigurácie konečného automatu  $M$ , kde  $p, q \in Q$ ,  $a \in \Sigma \cup \{\varepsilon\}$  a  $x \in \Sigma^*$ . Nech  $r = pa \rightarrow q \in R$  je pravidlo. Potom  $M$  môže previesť *prechod* z  $\chi_1$  do  $\chi_2$  aplikáciou pravidla  $r$ . Tento prechod zapíšeme:

$$pax \vdash qx[r] \text{ alebo } \chi_1 \vdash \chi_2[r]$$

---

<sup>1</sup>Anglicky Finite Automata

**Definícia 4.1.3.** Nech  $\chi_0, \chi_1, \dots, \chi_n$ , je sekvenčia prechodov konfigurácií pre  $n \geq 1$  a  $\chi_{i-1} \vdash \chi_i[r_i], r_i \in R$  pre všetky  $i = 1, \dots, n$ . Čo znamená:

$$\chi_0 \vdash \chi_1[r_1] \vdash \chi_2[r_2] \dots \vdash \chi_n[r_n]$$

Potom  $M$  prevedie  $n$ -prechodov z  $\chi_0$  do  $\chi_n$ , zapisujeme.

$$\chi_0 \vdash^n \chi_n[r_n \dots r_n] \text{ alebo } \chi_0 \vdash^n \chi_n$$

Ak  $\chi_0 \vdash^n \chi_n[\rho]$  pre nejaké  $n \geq 1$ , potom:

$$\chi_0 \vdash^+ \chi_n[\rho]$$

Ak  $\chi_0 \vdash^n \chi_n[\rho]$  pre nejaké  $n \geq 0$ , potom:

$$\chi_0 \vdash^* \chi_n[\rho]$$

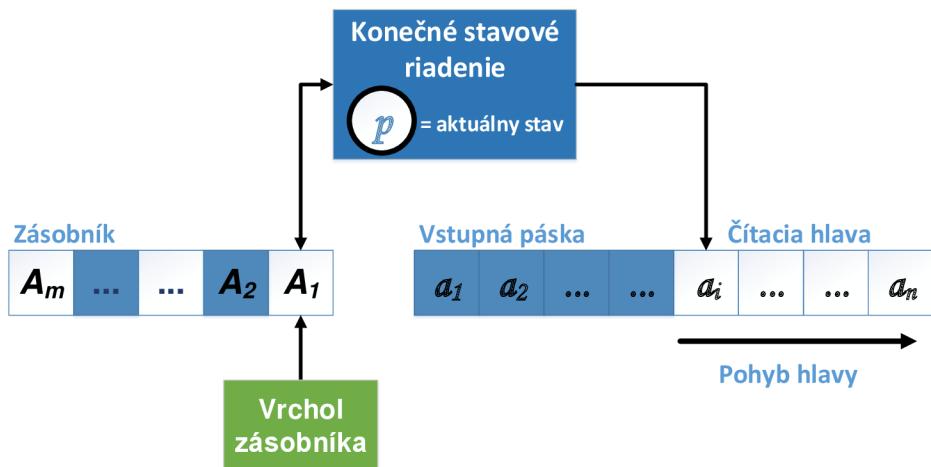
**Definícia 4.1.4.** Majme konečný automat  $M$  (4.1.1), potom *jazyk prijímaný* konečným automatom  $M, L(M)$ , je definovaný ako:

$$L(M) = \{w : w \in \Sigma^*, sw \vdash^* f, f \in F\}$$

Teda konečný automat  $M$  prijíma reťazec  $w$ , ak je prečítaný pomocou sekvenčie prechodov a automat skončí v koncovom stave.

## 4.2 Zásobníkové automaty

Zásobníkový automat je konečný automat, ktorý je rozšírený o zásobník (viď obrázok 4.1.1). Tento automat prijíma rodinu jazykov **CF**, teda bezkontextové jazyky.



Obr. 4.1: Zásobníkový automat

Činnosť zásobníkového automatu spočíva v tom, že ak sa na vrchole zásobníka objaví vstupný symbol  $a$ , automat porovná symbol na vrchole zásobníka s aktuálnym vstupným symbolom. Ak sa zhodujú, vyjme symbol z vrcholu zásobníka a pokračuje v spracovávaní

nasledujúceho symbolu na vstupnej páske. Ak sa na vrchole zásobníka nachádza neterminál, automat expanduje tento symbol podľa daného pravidla.

Automat prijme - prečíta vstupný reťazec  $w$ , ak je schopný vykonať sekvenciu pohybov, vyprázdníť zásobník a skončiť vo finálnom stave. Požiadavok skončiť vo finálnom stave môže byť vyniechaný a je postačujúce, že po prečítaní reťazca bude zásobník prázdný.

**Definícia 4.2.1.** Zásobníkový automat je sedmica  $M = (Q, \Sigma, \Gamma, R, s, S, F)$ , kde

- $Q$  je konečná množina stavov,
- $\Sigma$  je vstupná abeceda,
- $\Gamma$  je abeceda zásobníkových symbolov,
- $R$  je konečná množina pravidiel tvaru:  $A\alpha \rightarrow wq$ , kde

$$A \in \Gamma, p, q \in Q, \alpha \in \Sigma \cup \{\varepsilon\}, w \in \Gamma^*$$

- $s \in Q$  je počiatočný stav,
- $S \in \Gamma$  je počiatočný zásobníkový symbol,
- $F \subseteq Q$  je množina koncových stavov,

## Kapitola 5

# Regulované automaty

Tieto automaty boli prvý krát predstavené v roku 2000, v článku *Regulated Pushdown Automata* [2]. V článku je taktiež k dispozícii dôkaz, že táto regulácia zásobníkových automatov nemá žiadny efekt na výpočetnú silu zásobníkového automatu, ak je riadiaci jazyk regulárny.

V prípade, ak sú zásobníkové automaty regulované lineárnym riadiacim jazykom, majú väčšiu silu. Zásobníkové automaty regulované lineárnym jazykom charakterizujú rodinu rekurzívne vyčísliteľných jazykov.

Neskôr v roku 2001 boli predstavené jedno-otáčkové regulované zásobníkové automaty v článku *One-Turn Regulated Pushdown Automata and Their Reduction* [4]. Ak automat počas prvého kroku neskráti svoj zásobník a počas druhého kroku sa tak stane, potom urobí „otáčku“ počas druhého kroku. Zásobníkový automat je „jedno-otáčkový“ v prípade ak neurobí viac „otáčkových“ pohybov v priebehu ktoréhokoľvek výpočtu od počiatocnej konfigurácie. V článku je dokázané, že jedno-otáčkové regulované zásobníkové automaty charakterizujú rodinu rekurzívne vyčísliteľných jazykov **RE** (3.1.1). Jedno-otáčkové regulované zásobníkové automaty sú rovnako mocné ako regulované zásobníkové automaty, ktoré môžu urobiť ľubovoľný počet „otáčok“, avšak ich mechanizmus je jednoduchší.

Následne boli v článku *Self-Regulating Finite Automata* [5] predstavené *sebariadiace automaty*, ktoré regulujú výber pravidla podľa toho, aké pravidlo bolo aplikované v predchádzajúcim kroku.

Spomínané články boli uverejnené vo vedeckom časopise Acta Cybernetica.

### 5.1 Zásobníkové automaty regulované riadiacim jazykom

Na úvod si definujeme zásobníkové automaty, ktoré regulujú aplikáciu pravidla riadiacim jazykom. Ako už bolo spomenuté, regulovanie automatu pomocou regulárneho jazyku neprihŕňa žiadne zvýšenie sily zásobníkového automatu, preto sa zameriame konkrétnie na automaty regulované lineárnym riadiacim jazykom. Zásobníkový automat regulovaný riadiacim lineárnym jazykom má väčšiu výpočetnú silu ako obyčajný zásobníkový automat, čo je dokázané v publikácii [6] v sekcií 16.2.3. Predstavíme si základnú verziu tohto typu automatu a špeciálny automat - *Jedno - otáčkový automat regulovaný riadiacim jazykom*, ktorý je lineárny.

**Definícia 5.1.1.** Nech  $M = (Q, \Sigma, \Gamma, R, s, S, F)$  je zásobníkový automat (4.2.1) a  $\Psi$  je abeceda identifikátorov jeho pravidiel. Každé pravidlo  $Apa \rightarrow wq$  označíme jedinečným

identifikátorom  $\rho \in \Psi$  ako  $\rho.Apa \rightarrow wq$ . Potom  $\Xi$  je *riadiaci jazyk* nad abecedou  $\Psi$ , teda  $\Xi \subseteq \Psi^*$ .

*Konfigurácia* automatu  $M, \chi$ , je každý reťazec z  $\Gamma^* Q \Sigma^*$ . Pre každé  $x \in \Gamma^*, y \in \Sigma^*$  a  $\rho.Apa \rightarrow wq \in R$  automat  $M$  vykoná prechod z konfigurácie  $xApay$  do konfigurácie  $xwqy$  podľa pravidla  $\rho$ . Tento prechod zapíšeme ako:

$$xApay \Rightarrow xwqy[\rho]$$

**Definícia 5.1.2.** Nech  $\chi_0, \chi_1, \dots, \chi_n$ , je sekvencia konfigurácií pre  $n \geq 1$  a  $\chi_{i-1} \Rightarrow \chi_i[\rho_i]$ , kde  $\rho_i \in \Psi$  pre všetky  $i = 1, \dots, n$ , potom sa automat  $M$  n-tými prechodmi presunie z  $\chi_0$  do  $\chi_n$  podľa  $[\rho_1 \dots \rho_n]$ . Zapíšeme ako:

$$\chi_0 \Rightarrow^n \chi_n[\rho_1 \dots \rho_n]$$

Automat  $M$  prijme vstupný reťazec  $x$  iba v prípade, ak  $\Xi$  obsahuje riadiaci reťazec, podľa ktorého automat  $M$  vykonal sekvenciu krokov, teda po prečítaní reťazca  $x$  prešiel do konečnej konfigurácie.

**Definícia 5.1.3.** Pomocou dvojice  $(M, \Xi)$ <sup>1</sup> definujeme nasledujúce akceptovateľné jazyky:

- $L(M, \Xi, 1)$  - *jazyk akceptovaný finálnym stavom*
- $L(M, \Xi, 2)$  - *jazyk akceptovaný prázdnym zásobníkom*
- $L(M, \Xi, 3)$  - *jazyk akceptovaný finálnym stavom a prázdnym zásobníkom*

Nech  $\chi \in \Gamma^* Q \Sigma^*$ . Ak  $\chi \in \Gamma^* F$ ,  $\chi \in Q$ ,  $\chi \in F$ , potom  $\chi$  je 1 - *finálna konfigurácia*, 2 - *finálna konfigurácia*, 3 - *finálna konfigurácia*.

Pre  $i = 1, 2, 3$ , definujeme :

$$L(M, \Xi, i) = \{w | w \in \Sigma^* \text{ a } Ssw \vdash_M^* \chi[\sigma] \text{ pre každú } i\text{-finálnu konfiguráciu } \chi \text{ a } \sigma \in \Xi\}$$

Pre každú rodinu jazykov  $\mathcal{L}$  a  $i \in \{1, 2, 3\}$ , definujeme **RPDA**<sup>2</sup>

$$(\mathcal{L}, i) = \{L | L = L(M, \Xi, i), \text{kde } M \text{ je zásobníkový automat a } \Xi \in \mathcal{L}\}.$$

Z dôkazov, ktoré sa nachádzajú v publikácii [6] (na stranach 548 - 558) vieme, že *bezkontextový jazyk* (**CF**) je akceptovateľný regulovaným zásobníkovým automat, ktorý riadi *regulárny jazyk*. A rodinu *rekurzívne vyčísliteľných jazykov* (**RE**) akceptuje regulovaný zásobníkový automat, ktorý riadi *lineárny jazyk*. Teda platí:

$$\begin{aligned} CF &= RPDA(REG, 1) = RPDA(REG, 2) = RPDA(REG, 3) \text{ a} \\ RE &= RPDA(LIN, 1) = RPDA(LIN, 2) = RPDA(LIN, 3) \end{aligned}$$

---

<sup>1</sup>Dvojicu  $(M, \Xi)$  nazývame riadený zásobníkový automat.

<sup>2</sup>Regulovaný zásobníkový automat budeme označovať *RPDA*, čo je odvodená skratka z jeho anglického názvu - Regulated Pushdown Automata.

**Príklad 5.1.1.** Ukážeme si jednoduchý príklad pre demonštráciu rozdielu automatu, ktorý nie je regulovaný a automatu, ktorý je regulovaný riadiacim jazykom.

Uvažujme regulovaný zásobníkový automat  $M$  z definície 4.2.1 s nasledujúcimi pravidlami:

1.  $Ssa \rightarrow Sas$
2.  $asa \rightarrow aas$
3.  $asb \rightarrow q$
4.  $aqb \rightarrow q$
5.  $Sqc \rightarrow Sq$
6.  $Sqc \rightarrow f$

Tento zásobníkový automat prijíma reťazec  $aabbccc$ :

$$\begin{aligned}
 Ssaabbccc &\Rightarrow Sasabbccc [1] \\
 &\Rightarrow Saasbbccc [2] \\
 &\Rightarrow Saqbccc [3] \\
 &\Rightarrow Sqccc [4] \\
 &\Rightarrow Sqcc [5] \\
 &\Rightarrow Sqc [5] \\
 &\Rightarrow f [6]
 \end{aligned}$$

Postupnosť pravidiel: **1234556**.

Automat  $M$  akceptuje jazyk  $L(G) = \{a^n b^n c^m : n, m \geq 1\}$ .

Prijatie reťazca  $aabbcc$  zásobníkovým automatom  $M$  regulovaným riadiacim jazykom  $\Xi = \{12^m 34^n 5^n 6 : m, n \geq 0\}$ :

$$\begin{aligned}
 Ssaabbcc &\Rightarrow Sasabbcc [1] \\
 &\Rightarrow Saasbbcc [2] \\
 &\Rightarrow Saqbcc [3] \\
 &\Rightarrow Sqcc [4] \\
 &\Rightarrow Sqc [5] \\
 &\Rightarrow f [6]
 \end{aligned}$$

Postupnosť pravidiel: **123456** patrí riadiacemu jazyku  $\Xi$ .

Automat  $M$  regulovaný riadiacim jazykom  $\Xi$  generuje jazyk  $L(G, \Xi) = a^n b^n c^n : n \geq 1$ .

Napriek tomu, že boli využité rovnaké pravidlá pre akceptovanie reťazca automatom  $M$  je z uvedených príkladov zrejmé, že reťazec  $aabbccc$  nie je možné akceptovať automatom  $M$  regulovaným riadiacim jazykom z vyššie uvedeného príkladu, pretože postupnosť pravidiel  $1234556 \notin \Xi = \{1\}\{24\}^*\{35\}$ .

## 5.2 Zásobníkové automaty regulované lineárnym riadiacim jazykom

V nasledujúcich odstavcoch si ukážeme úryvok dôkazu formálneho zstrojenia zásobníkového automatu, ktorý je regulovaný lineárnym jazykom. Ako prvú zstrojíme lineárnu gramatiku, pre generovanie riadiaceho jazyka, ktorú odvodíme z ľavo-rozšírenej frontovej gramatiky. Celý dôkaz je k dispozícii v texte [2].

Majme nasledujúce entity:

- Ľavo-rozšírenú frontovú gramatiku  $\mathbf{Q} = (V[Q], T[Q], W[Q], F[Q], s[Q], P[Q])$ <sup>3</sup> z definície 3.2.1. Bez straty všeobecnosti predpokladajme  $\{@, \mathcal{L}, \Psi\} \cap (V[Q] \cup W[Q]) = \emptyset$ . Definujme si značenie  $\zeta$  z  $(V[Q])^*$  do  $\{\langle \mathcal{L}as \rangle | a \in V[Q]\}^*$  ako  $\zeta(a) = \{\langle \mathcal{L}as \rangle\}$ , kde  $s$  je použité ako štartovací stav zásobníkového automatu  $M$ .
- lineárnu gramatiku  $\mathbf{G} = (N[G], T[G], P[G], S[G])$  (3.1.5), ktorú zostrojíme nasledovne:
  - $N[G] = \{S[G], \langle ! \rangle, \langle !, 1 \rangle\} \cup \{\langle f \rangle | f \in F[Q]\}$ ,
  - $T[G] = \zeta(V[Q]) \cup \{\langle \mathcal{L}\$s \rangle, \langle \mathcal{L}@ \rangle\} \cup \{\langle \mathcal{L}\$f \rangle | f \in F[Q]\}$ ,
  - $P[G] = \{S[G] \rightarrow \langle \mathcal{L}\$s \rangle \langle f \rangle | f \in F[Q]\} \cup \{\langle ! \rangle \rightarrow \langle !, 1 \rangle \langle \mathcal{L}@ \rangle\}$
- zásobníkový automat  $\mathbf{M} = (Q[M], \Sigma[M], \Gamma[M], R[M], s, S[M], \{| \})$  (4.2.1), kde
  - $Q[M] = \{s, \langle \Psi! \rangle, \lfloor, \rfloor\}$ ,
  - $\Sigma[M] = \{S[M], \$\} \cup V[Q]$ ,
  - $R[M] = \{\langle \mathcal{L}\$s \rangle . S[M] \rightarrow \$s\} \cup \{\langle \mathcal{L}\$f \rangle . \$ \langle \Psi f \rangle \rightarrow \rfloor | f \in F[M]\}$

Bude platiť, že  $L(Q) = L(M, L(G), 3)$ .

Gramatiku  $G$  rozšírimo aplikovaním nasledujúcich krokov pre každé pravidlo  $(a, p, x, q) \in P[Q]$  pomocou gramatiky  $Q^4$ , kde

1.  $p, q \in W[Q], a \in Z, x \in T^*$ ,

$$\begin{aligned} N[G] &= N[G] \cup \{\langle apxqk \rangle | k = 0, \dots, |x|\} \cup \{\langle p \rangle, \langle q \rangle\} \\ T[G] &= T[G] \cup \{\langle \mathcal{L}\text{sym}(y, k) \rangle | k = 1, \dots, |y|\} \cup \{\langle apxq \rangle\} \\ P[G] &= P[G] \cup \{\langle q \rangle \rightarrow \langle apxq|x\rangle \langle \mathcal{L}apxq \rangle, \langle apxq0 \rangle \rightarrow \langle p \rangle\} \\ &\quad \cup \{\langle apxqk \rangle \rightarrow \langle apxq(k-1) \rangle \langle \mathcal{L}\text{sym}(x, k) \rangle | k = 1, \dots, |x|\} \end{aligned}$$

2.  $p, q \in W[Q], a \in U, x \in (W[Q])^*$ ,

$$\begin{aligned} N[G] &= N[G] \cup \{\langle p, 1 \rangle, \langle q, 1 \rangle\} \\ P[G] &= P[G] \cup \{\langle q, 1 \rangle \rightarrow \text{reversal}(\zeta(x)) \langle p, 1 \rangle \zeta(a)\} \end{aligned}$$

3.  $ap = S[Q], p, q \in W[Q], x \in (W[Q])^*$ ,

$$\begin{aligned} N[G] &= N[G] \cup \{\langle q, 1 \rangle\} \\ P[G] &= P[G] \cup \{\langle q, 1 \rangle \rightarrow \text{reversal}(x) \langle \mathcal{L}\$s \rangle\} \end{aligned}$$

Konštrukcia gramatiky  $G$  je komplettná. Množina terminálov gramatiky  $T[G] \in G$  bude abeceda identifikátorov pravidiel zásobníkového automatu  $M$ ,  $\Psi = T[G]$ .

Množinu stavov automatu  $Q[M]$  a množinu jeho pravidiel  $R[M]$  rozšírimo aplikovaním nasledujúcich krokov.

1.  $R[M] = R[M] \cup \{\langle \mathcal{L}bs \rangle . as \rightarrow abs | a \in \Gamma[M] - \{S[M]\}, b \in \Gamma[M] - \{\$\}\};$
2.  $R[M] = R[M] \cup \{\langle \mathcal{L}\$s \rangle . as \rightarrow a | a \in V[Q]\} \cup \{\langle \mathcal{L}a \rangle . a | a \in V[Q]\};$

---

<sup>3</sup>Gramatika  $Q$  využitá pre ukážku formálneho zostrojenia lineárnej gramatiky a automatu musí splňovať vlastnosti dôkazu "Lemma 3" z článku [2].

<sup>4</sup>Pre lepšie pochopenie vzťahov množín Ľavo-rozšírenej frontovej gramatiky pozri obrázok 3.2

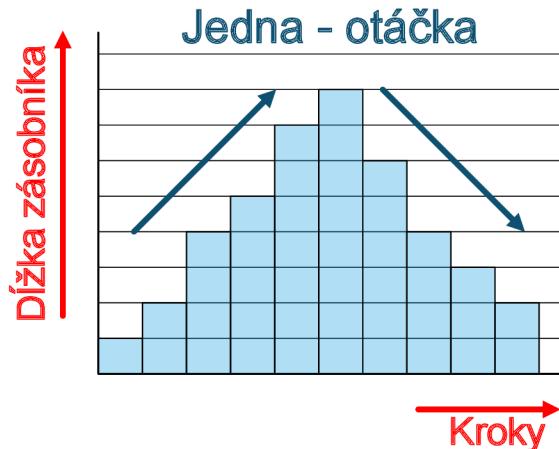
3.  $R[M] = R[M] \cup \{\langle \mathcal{L} @ \rangle.a | \rightarrow a \langle \P! \rangle | a \in Z\};$
4. pre každé pravidlo  $(a, p, x, q) \in P[Q]$ , kde  $p, q \in W[Q], a \in Z, x \in (T[Q])^*$ ,

$$\begin{aligned} Q[M] &= Q[M] \cup \{\langle \P p \rangle\} \cup \{\langle \P qu \rangle | u \in \text{prefix}(x)\} \\ R[M] &= R[M] \cup \{\langle \mathcal{L} b \rangle.a \langle \P qy \rangle b \rightarrow a \langle \P qyb \rangle | b \in T[Q], y \in (T[Q])^*, \\ &\quad yb \in \text{prefix}(x)\} \cup \{\langle \mathcal{L} apxq \rangle.a \langle \P qx \rangle \rightarrow \langle \P p \rangle q\}. \end{aligned}$$

Konštrukcia automatu  $M$  je kompletnej. Ak  $x$  začína s  $\mathcal{L}$ , potom  $\langle x \rangle \in T[G]$ . Ak  $x$  začína s  $\P$ , potom  $\langle x \rangle \in Q[M]$ . Ak  $x$  začína iným symbolom, potom  $\langle x \rangle \in N[G]$ .

### 5.2.1 Jedno-otáčkový atomický zásobníkový automat regulovaný lineárnym jazykom

Uvažujme dva po sebe nasledujúce kroky, ktoré vykoná zásobníková automat  $M$  (4.2.1). Ak počas prvého kroku  $M$  neskráti dĺžku svojho zásobníka a počas druhého skráti, tak potom  $M$  vykoná „otáčku“ počas druhého kroku.



Obr. 5.1: Jedno-otáčkový zásobníkový automat

Zásobníkový automat je *jedno - otáčkový* ak neurobí viac „otáčok“ v priebehu ktoréhokoľvek výpočtu od počiatočnej konfigurácie.

Počas pohybu *atomický* regulovaný zásobníkový automat zmení stav a vykoná iba jednu z nasledujúcich akcií:

1. vloží symbol na zásobník
2. vyjme symbol zo zásobníka
3. číta symbol z vstupnej pásky

**Definícia 5.2.1.** *Atomický zásobníkový automat* je sedmica  $M = (Q, \Sigma, \Omega, R, s, \$, F)$ , kde

- $Q$  je konečná množina stavov;
- $\Sigma$  je vstupná abeceda;

- $\Omega$  je abeceda zásobníkových symbolov,  $Q$ ,  $\Sigma$  a  $\Omega$  sú v páre disjunktné, t.j. ich prienik je prázdna množina;
- $\$$  je symbol značiaci dno zásobníka, kde  $\$ \notin Q \cup \Sigma \cup \Omega$ ;
- $F \subseteq Q$  je množina koncových stavov;
- $R$  je konečná množina pravidiel tvaru:  $Apa \rightarrow wq$ , kde  $p, q \in Q, A, w \in \Omega \cup \{\varepsilon\}, a \in \Sigma \cup \{\varepsilon\}$ , tak že  $|Aaw| = 1$ . To znamená, že  $R$  je konečná množina pravidiel, kde každé pravidlo má niektorý z nasledujúcich tvarov:
  1.  $Ap \rightarrow q$  (pravidlo vkladania symbolu na zásobník)
  2.  $p \rightarrow wq$  (pravidlo pre odstránenie symbolu zo zásobníka)
  3.  $pa \rightarrow q$  (pravidlo čítania vstupného symbolu)

Nech každé pravidlo má identifikátor  $\rho$ , potom  $\Psi$  je abeceda týchto identifikátorov a  $\psi$  mapuje pravidlo,  $Apa \rightarrow wq \in R$  do  $\rho$ . Formálny zápis:  $\rho.Apa \rightarrow wq \in R$ . Inými slovami  $\rho.Apa \rightarrow wq$  znamená  $\psi(Apa \rightarrow wq) = \rho$ . Konfigurácia automatu  $M$ ,  $\chi$  je ľubovoľný reťazec z  $\{\$\} \Omega^* Q \Sigma^*$ .

$\chi$  je počiatočná konfigurácia, ak  $\chi = \$sw$ , kde  $w \in \Sigma^*$ . Pre každé  $x \in \Omega^*$ ,  $y \in \Sigma^*$  a  $\rho.Apa \rightarrow wq \in R$ ,  $M$  urobí pohyb z konfigurácie  $\$xApay$  do konfigurácie  $\$xwqy$  podľa  $\rho$ . Toto formálne zapíšeme ako  $\$Apay \Rightarrow \$xwqy[\rho]$ .

Nech  $\chi$  je ľubovoľná konfigurácia automatu  $M$ .  $M$  urobí nula pohybov z  $\chi$  do  $\chi$  podľa  $\varepsilon$ , symbolicky zapísané  $\chi \Rightarrow^0 \chi[\varepsilon]$ . Nech existuje sekvenca konfigurácií  $\chi_0, \chi_1, \dots, \chi_n$  pre  $n \geq 1$ , potom  $\chi_i - 1 \Rightarrow \chi_i[i]$ , kde  $\rho_i \in \Psi$ , pre  $i = 1, \dots, n$ , potom  $M$  urobí  $n$  pohybov z  $\chi_0$  do  $\chi_n$  podľa pravidiel  $\rho_1 \dots \rho_n$ , symbolicky zapísané ako  $\chi_0 \Rightarrow^n \chi_n[\rho_1 \dots \rho_n]$ , zjednodušene  $\chi_0 \Rightarrow \chi_n$ .  $\Rightarrow^*$  a  $\Rightarrow^+$  je definované štandardným spôsobom.

Majme  $x, x', x'' \in \Omega^*$ ,  $y, y', y'' \in \Sigma^*$ , a  $\$xq \Rightarrow \$x'q'y' \Rightarrow \$x''q''y''$ . Ak  $|x| \leq |x'|$  a  $|x'| > |x''|$ , potom  $\$x'q'y' \Rightarrow \$x''q''y''$  je *otočka*. Ak  $M$  neurobí viac ako jednu otočku počas ktorejkoľvek sekvencie pohybov štartujúcej z počiatočnej konfigurácie, potom automat  $M$  nazývame **jedno-otáčkový**.

## Kapitola 6

# Syntaktická analýza v prekladačoch

V nasledujúcej kapitole si v skratke predstavíme činnosť *prekladača* a jeho jednotlivé fázy. Podrobnejšie sa budeme venovať srdcu prekladača - *syntaktickému analyzátoru*, ktorý okrem vykonávania syntatickej analýzy, riadi a kontroluje ostatné komponenty prekladača.

**Prekladač**, taktiež nazývaný ako komplilátor, je program, ktorý slúži pre preklad algoritmov zapísaných vo vyššom programovacom jazyku (napr. C, C++) do jazyka nižšieho, najčastejšie do strojového kódu. Na vstupe prijíma zdrojový program zapísaný v zdrojovom jazyku, aby na výstupe generoval funkčne ekvivalentný cieľový program v cieľovom jazyku.

Transformáciu, ktorú prevádzza prekladač nazývame *preklad*. Preklad zdrojového programu prebieha v šiestich fázach:

- Lexikálna analýza
- Syntaktická analýza
- Sémantická analýza
- Generátor vnútorného kódu
- Optimalizácia
- Generátor cieľového kódu

Jednotlivé fázy spolu aj so vstupmi a výstupmi prekladača sú zobrazené na obrázku 6.1.

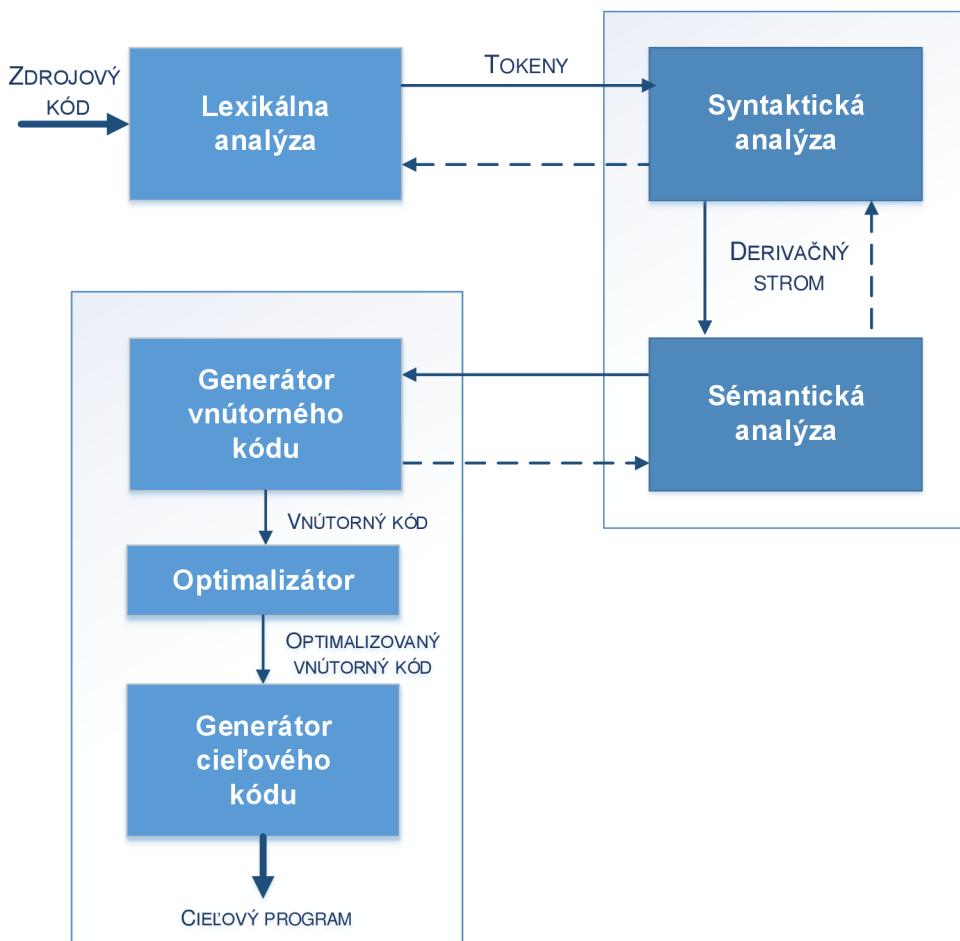
*Lexikálna analýza* rozloží zdrojoví kód na lexémy - lexikálne jednotky - tokeny, čo sú jednotlivé rozoznané elementy zdrojového jazyka. Napríklad identifikátory, zápisy čísel, klúčové slová, a pod. Lexikálna analýza produkuje *tokeny*, ktoré sú vstupom pre syntaktickú analýzu. Činnosť lexikálnej analýzy je zobrazená na obrázku 6.2.

Úlohou *syntaktickej analýzy* v prekladačoch je rozpoznať, či zadaná postupnosť znakov - zdrojový kód, je syntakticky správna. V kladnom prípade je výstupom syntaktickej analýzy derivačný strom tokenov, ktorý reprezentuje program. Program, ktorý túto analýzu vykonáva sa nazýva *syntaktický analyzátor*<sup>1</sup>.

*Sémantický analyzátor* vykonáva kontrolu rôznych sémantických aspektov programu, ako napr. deklaráciu premenných.

---

<sup>1</sup>Anglicky sa syntaktický analyzátor nazýva **parser**



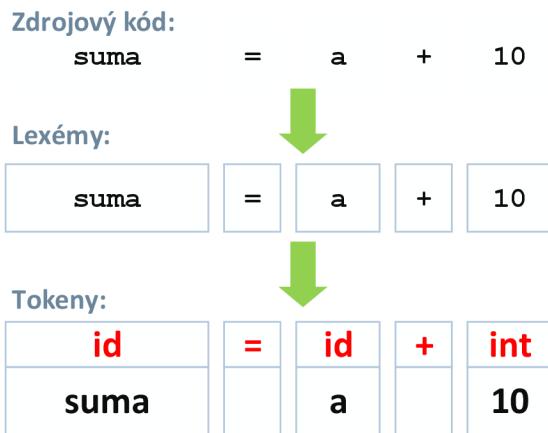
Obr. 6.1: Prekladač

*Generátor kódu* vytvorí na základe derivačného stromu zdrojového programu cieľový kód. Generovanie kódu sa skladá z troch fáz: generovanie vnútorného kódu, optimalizácia a generovanie cieľového programu.

Týchto šesť komponentov prekladača úzko spolupracuje. Syntaktický analyzátor kontroluje a riadi ostatné komponenty. Na základe príkazu syntaktického analyzátora lexikálny analyzátor číta zdrojový program, pripraví token a pošle ho syntaktickému analyzátoru. Syntaktický analyzátor taktiež kontroluje sémantickú analýzu a dáva príkaz generátoru kódu, aby vytvoril cieľový program.

Fáza syntaktickej analýzy je oveľa zložitejšia než predchádzajúca fáza prekladu, teda lexikálna analýza. Lexémy sú popísané regulárnym jazykom, ktorý dokáže jednoducho rozoznať a prijať konečný automat. Syntaktický analyzátor rozpoznáva zložitejšie jazyky. Najčastejšie je to bezkontextový jazyk, ktorý popisuje aj programovacie jazyky a tento jazyk je akceptovaný zásobníkovým automatom.

Ako už bolo spomenuté syntaktická analýza je dôležitou časťou spracovania programu pri jeho preklade, pretože prevádzka analýzu vstupného jazyka. Rozoznáva, či je program zapísaný syntakticky správnym spôsobom. Napríklad v jazyku C, zistí či blok programu,

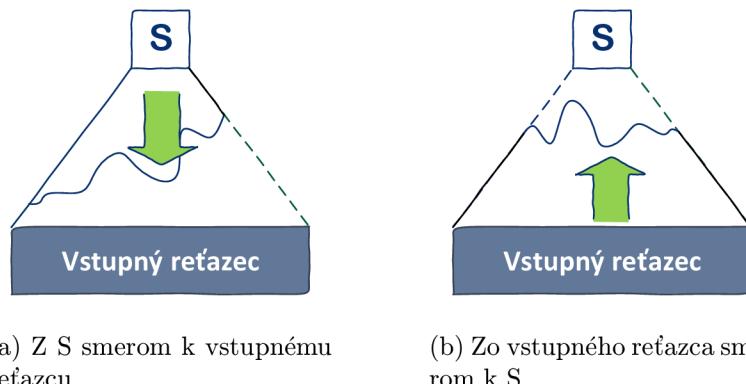


Obr. 6.2: Lexikálna analýza - rozoznanie lexikálnych jednotiek v zdrojovom kóde

ktorý začal „{“ je následne ukončený „}“ alebo určuje v akom poradí sa budú prevádzkať jednotlivé príkazy, napr. „ $a + b * c$ “. V tomto prípade určí, že sa ako prvé vykoná násobenie a následne sčítanie. Ak je k danému reťazcu tokenov nájdený *derivačný strom*, program je správny.

Vytváranie derivačného stromu je založené na gramatických pravidlách. Existujú dva prístupy syntaktickej analýzy *zhora dole* a *zdola na horu* (viď obrázok 6.3). Syntaktická analýza založená na princípe *zhora dole* prekladá vety bezkontextového jazyka na ich ľavé rozbory. Tento syntaktický analyzátor začína s počiatočným symbolom gramatiky a postupným aplikovaním pravidiel vytvára derivačný strom, kde listy tvoria vstupný reťazec.

Syntaktická analýza založená na princípe *zhora dole* prekladá vety bezkontextového jazyka na ich pravé rozbory. Tento syntaktický analyzátor začína so vstupným reťazcom - listami derivačného stromu, na ktoré uplatňuje pravidlá a postupne vytvára podstromy, ktoré spája. Koreňom tohto vytvoreného stromu je počiatočný symbol gramatiky.



Obr. 6.3: Vytváranie derivačného stromu

## Kapitola 7

# Zstrojenie syntaktického analyzátora

V nasledujúcej kapitole si zstrojíme syntaktický analyzátor a potrebné entity, pre jeho činnosť.

Náplňou tejto práce je zstrojiť syntaktickú analýzu, ktorá je založená na regulovaných zásobníkových automatoch. Ako už bolo spomenuté v kapitole 5.1 regulácia zásobníkových automatov riadiacim jazykom, ktorý je regulárny nemá žiadny efekt na silu zásobníkového automatu, preto zvolíme ako riadiaci jazyk, jazyk lineárny.

Zásobníkové automaty regulované riadiacim lineárnym jazykom sú schopné prijať rodinu rekurzívne vyčísliteľných jazykov **RE** (3.1.1). Túto rodinu jazykov generuje frázová gramatika.

Cinnosť frázovej gramatiky budeme v tomto prípad simulovať použitím dvoch lineárnych gramatík. Pomocou prvej gramatiky vygenerujeme časť reťazca a postupnosť pravidiel, ktoré boli aplikované pri generovaní reťazca, použijeme ako riadiaci jazyk pre druhú z týchto lineárnych gramatík.

Aplikovateľnosť a implementovateľnosť tejto metódy syntaktickej analýzy prevedieme pomocou nasledujúceho jednoduchého rekurzívne vyčísliteľného jazyka, ktorý bude akceptovateľný našim zstrojeným syntaktickým analyzátorom, teda taktiež našim automatom regulovaným riadiacim jazykom, ktorý je lineárny.

### 7.1 Generovanie reťazca rekurzívne vyčísliteľného jazyka

Majme jazyk z rodiny **RE**:

$$L(M) = \{a^n b^n c^n : n \geq 1\}$$

Tento jazyk bude generovaný dvomi lineárnymi gramatikami.

Majme lineárnu gramatiku  $G = (N[G], T[G], P[G], S)$  z definície 3.1.5, kde

- $N[G] = S$
- $T[G] = \{a, c\}$
- $P[G] = \{1: S \rightarrow aSc\}$
- $S \in N[G]$ , je počiatočný neterminál.

Generovanie reťazca gramatikou G:

$$\begin{aligned} S &\Rightarrow aSc & [1] \\ &\Rightarrow aaScc & [1] \\ &\Rightarrow aaaSccc & [1] \\ &\Rightarrow aaaaScccc & [1] \end{aligned}$$

Postupnosť pravidiel: **1111** využijeme ako riadiaci jazyk pre generovanie zvyšnej časti reťazca  $\Xi = \{1111\}$ . Ako vidíme pravidlo **1** bolo aplikované štyri krát. Môžeme využiť skrátený zápis  $\Xi = \{1\}^4$ .

Majme gramatiku  $Q = (N[Q], T[Q], P[Q], S)$  z definície 3.1.5, kde

- $N[Q] = S$
- $T[Q] = \{b\}$
- $P[Q] = \{1: S \rightarrow Sb, 2: S \rightarrow \epsilon\}$
- $S \in N[Q]$ , je počiatočný neterminál.

Gramatika reguluje aplikovanie pravidiel pomocou riadiaceho lineárneho jazyka  $\Xi = \{1111\}$ . Po ukončení generovania reťazca je potrebné odstrániť neterminál  $S$ , čo vykonáme aplikovaním pravidla **2**. Toto pravidlo pridáme na koniec riadiaceho jazyka, teda

$$\Xi = \Xi \cup \{2\} = \{11112\} = \{1\}^4\{2\}$$

Pomocou tejto gramatiky a riadiaceho jazyka  $\Xi = \{1111112\}$  vygenerujeme strednú časť reťazca nasledovne:

$$\begin{aligned} aaaaaaScccccc &\Rightarrow aaaaSbcccc & [1] & \Xi = \{11112\} \\ &\Rightarrow aaaaSbbccc & [1] & \Xi = \{1112\} \\ &\Rightarrow aaaaSbbbccc & [1] & \Xi = \{112\} \\ &\Rightarrow aaaaSbbbbccc & [1] & \Xi = \{12\} \\ &\Rightarrow aaaabbbccc & [1] & \Xi = \{2\} \end{aligned}$$

Reťazec  $aaaabbbccc$  vygenerovaný gramatikami  $G$  a  $Q$  patrí jazyku  $L(M) = \{a^n b^n c^n : n \geq 1\}$ .

## 7.2 Zostrojenie automatu regulovaného riadiacim lineárnym jazykom

Majme Zásobníkový automat  $M = (Q, \Sigma, \Gamma, R, s, S, F)$  z definície 4.2.1, kde

- $Q = \{s, q, f\}$ ,
- $\Sigma = \{a, b, c\}$ ,
- $\Gamma = \{a, S\}$ ,
- $R = \{1: Ss \rightarrow q, 2: qa \rightarrow aq, 3: aqb \rightarrow q, 4: qc \rightarrow q, 5: Sq \rightarrow f\}$
- $s \in Q$  je počiatočný stav,

- $S \in \Gamma$  je počiatočný zásobníkový symbol,
- $F \subseteq Q$  je množina koncových stavov,

Tento automat bude prijímať jazyk  $L(M, \Xi, 3) = \{a^n b^n c^n : n \geq 1\}$  a aplikáciu pravidiel bude regulovať lineárnym jazykom, ktorý generuje lineárna gramatika  $G$ , kde

$$\Psi[M] = T[G]$$

Majme lineárnu gramatiku  $G = (N[G], T[G], P[G], S)$  z definície 3.1.5, kde

- $N[G] = \{S, X\}$
- $T[G] = \{1, 2, 3, 4, 5\}$
- $P[G] = \{1: S \rightarrow 12X5, 2: X \rightarrow 3X4, 3: X \rightarrow \varepsilon\}$
- $S \in N[G]$ , je počiatočný neterminál.

Reťazec musí obsahovať rovnaký počet terminálov  $a$ ,  $b$  a  $c$ . Túto kontrolu prevedieme nasledujúcim spôsobom.

Na úvod vložíme na zásobník znak značiaci dno zásobníka  $\$$ , počiatočný symbol  $S$  a automat sa bude nachádzať v počiatočnom  $s$ . Gramatika  $G$  aplikuje pravidlo 1:  $S \rightarrow 12X5$ , aby vygenerovala počiatočný riadiaci jazyk pre automat, teda  $\Xi = \{12X5\}$ .

Automat podľa  $\Xi$  aplikuje formálne pravidlo 1:  $Ss \rightarrow q$ , prejde do stavu  $q$  a vyjme použité pravidlo  $\Xi = \{2X5\}$ .

Automat pomocou pravidla 2:  $qa \rightarrow aq$  vkladá na zásobník terminál  $a$ . Pri každej aplikácii tohto pravidla gramatika  $G$  aplikuje pravidlo 2:  $X \rightarrow 3X4$ ,  $\Xi = \{23X45\}$ . Automat  $M$  a gramatika  $G$  budú vykonávať túto činnosť dokiaľ sa na vstupnej páske bude nachádzať terminál  $a$ . Po skončení týchto iterácií bude použité pravidlo odstránené  $\Xi = \{3^n X 4^n 5\}$  a aplikované posledné pravidlo gramatiky  $G$  3:  $S \rightarrow \varepsilon$ ,  $\Xi = \{3^n 4^n 5\}$ .

Ako ďalšie začne aplikovať pravidlo 3:  $aqb \rightarrow q$ , ktoré zabezpečuje prijatie rovnakého počtu symbolov  $a$  a  $b$ . Počet použití tohto pravidla opäť reguluje riadiaci jazyk automatu  $\Xi = \{3^n 4^n 5\}$ . Symbol  $a$  je tentokrát čítaný zo zásobníka automatu a symbol  $b$  zo vstupnej pásky. Pri každom aplikovaní pravidla sú tieto symboly a použité pravidlo odstránené. Po vykonaní tejto časti  $\Xi = \{4^n 5\}$ .

Syntaktický analyzátor pokračuje v spracovávaní reťazca, kde overí počet výskytov podreťazca  $cccc$  a to aplikáciou pravidla 4:  $qc \rightarrow q$ , ktoré redukuje vstupný reťazec a spracováva symbol  $c$ . Analogicky symbol  $a$  a použité pravidlá sú odstránené. Po vykonaní tejto časti je vstupná páska prázdna a  $\Xi = \{5\}$ .

V tomto bode by sme mohli syntaktickú analýzu ukončiť a prehlásiť, že reťazec patrí danému jazyku. Avšak prijímaným jazykom je jazyk  $L(M, \Xi, 3)$ , teda jazyk je akceptovaný prázdnym zásobníkom a finálnym stavom. Preto riadiaci jazyk obsahuje posledné pravidlo  $\Xi = \{5\}$ .

Aplikujeme a odstráňme posledné pravidlo 5:  $Sq \rightarrow f$ ,  $\Xi = \{\}$ . Ak bola doposiaľ syntaktická analýza úspešná, overíme, či sa automat nachádza vo finálnom stave a či je zásobník prázdný. Ak sú všetky podmienky splnené, syntaktická analýza je správna a reťazec je akceptovaný automatom.

Všimnime si, že pri generovaní reťazca gramatikami  $G$  a  $Q$  bol postup odlišný. Najskôr sa vygenerovali dve časti reťazca  $a^n .. c^n$  - prefix a suffix (2.1.4), ktoré boli vygenerované

zároveň. Následne bol vytvorený podla postupnosti pravidiel riadiaci jazyk  $\Xi$  pre vygenerovanie podreťazca  $b^n$ . Na začiatku sme teda pomocou gramatík generovali  $a^n c^n$  a  $b^n$ , teraz spracujeme reťazec v tomto poradí  $a^n b^n$  a  $c^n$ .

V nasledujúcej tabuľke sa nachádza akceptovanie reťazca  $aaaabbbbcccc$ , ktorý sme vygenerovali v predchádzajúcej sekcií.

Zásobník	Stav	Vstupná páska	Pravidlo ( $M$ )	Riadiaci jazyk $\Xi$	Pravidlo ( $G$ )
\$S	q	aaaabbbbcccc\$	[1: $Ss \rightarrow q$ ]	$\Xi = \{12X5\}$	[1: $S \rightarrow 12X5$ ]
\$Sa	q	aaabbbbcccc\$	[2: $qa \rightarrow aq$ ]	$\Xi = \{23X45\}$	[2: $X \rightarrow 3X4$ ]
\$Saa	q	aabbccc\$c	[2: $qa \rightarrow aq$ ]	$\Xi = \{233X445\}$	[2: $X \rightarrow 3X4$ ]
\$Saaa	q	abbbbcccc\$	[2: $qa \rightarrow aq$ ]	$\Xi = \{2333X4445\}$	[2: $X \rightarrow 3X4$ ]
\$Saaaa ⊖	q	bbbbcccc\$	[2: $qa \rightarrow aq$ ]	$\Xi = \{333344445\}$	[3: $S \rightarrow \varepsilon$ ]
\$Saaa	q	bbbcccc\$	[3: $aqb \rightarrow q$ ]	$\Xi = \{333344445\}$	
\$Saa	q	bbcccc\$	[3: $aqb \rightarrow q$ ]	$\Xi = \{33344445\}$	
\$Sa	q	bcccc\$	[3: $aqb \rightarrow q$ ]	$\Xi = \{3344445\}$	
\$S	q	cccc\$	[3: $aqb \rightarrow q$ ]	$\Xi = \{344445\}$	
\$S	q	ccc\$	[4: $qc \rightarrow q$ ]	$\Xi = \{44445\}$	
\$S	q	cc\$	[4: $qc \rightarrow q$ ]	$\Xi = \{4445\}$	
\$S	q	c\$	[4: $qc \rightarrow q$ ]	$\Xi = \{445\}$	
\$S	q	\$	[4: $qc \rightarrow q$ ]	$\Xi = \{45\}$	
\$	f	\$	[5: $Sq \rightarrow f$ ]	$\Xi = \{5\}$	
\$	f	\$		$\Xi = \{\varepsilon\}$	

Značka  $\ominus$  značí vykonanie „otáčky“ automatom. Ak by sme demonštrovali činnosť jedno-otáčkového automatu (5.2.1), automat by po aplikácii sekvencie pravidiel typu 2 vykonal otočku. V tomto okamihu zásobník dosiahol najväčšiu dĺžku a ďalej sa už nebude zväčšovať, pretože sa budú aplikovať pravidlá, ktoré vykonávajú redukciu. Tento automat môžeme taktiež považovať za **jedno-otáčkový automat regulovaný riadiacim lineárnym jazykom**.

# Kapitola 8

## Implementácia

V tejto kapitole si popíšeme spôsob, akým bol implementovaný jednoduchý syntaktický analyzátor.

Prvotnou ideou bolo implementovať jeden program, ktorého činnosť by sa dala rozdeliť do dvoch fáz. V prvej fáze by bol generovaný reťazec pomocou frázovej gramatiky, simulovanej dvomi lineárnymi gramatikami 3.1.1. V druhej fáze by bol tento reťazec prijatý syntaktickým analyzátorom založeným na zásobníkovom automate, ktorý reguluje použitie pravidiel lineárnym jazykom.

V priebehu implementácie vznikla myšlienka rozdeliť tieto fázy na dva oddelené celky. Dôvodom bolo ukázať činnosť simulovanej frázovej gramatiky a schopnosť touto metódou generovať jazyk, ktorý sa skladá z neobmedzeného počtu symbolov a každý symbol sa v ňom nachádza práve  $n$ -krát:

$$L = \{symbol_1^n symbol_2^n \dots symbol_y^n : n \geq 1 \text{ a } y \geq 2\}.$$

V druhej fáze je zase zaujímavé sledovať chovanie automatu. Či už ako sa tento automat vysporiada s prijatím reťazca, ktorý nie je správny alebo so správnym reťazcom rôznej dĺžky. Automat je implementovaný pre jazyk<sup>1</sup>

$$L(M) = \{a^n b^n c^n : n \geq 1\}.$$

V rámci tejto bakalárskej práce boli implementované dva programy - `re_grammar` a `parser` v jazyku C, ktoré boli riešené formou konzolovej aplikácie. Tieto programy sú multiplatformové a boli testované na operačných systémoch Linux a Windows.

Každý program sa skladá z viacerých modulov. Dva moduly sú spoločné pre obidve časti. Prvý modul `stack.c` obsahuje implementáciu zásobníka a operácie nad touto štruktúrou. Druhý modul `color_text.c` je pomocný a využíva sa pri výpise farebného textu na štandardný výstup `STDOUT`.

### 8.1 Simulácia frázovej gramatiky

Frázová gramatika je implementovaná programom `re_grammar`, ktorý pozostáva z piatich modulov. Dva z nich už boli zmienené a sú zdielané s programom `parser`. Zvyšné tri si popíšeme v tejto sekcií.

---

<sup>1</sup>Analýza akceptovania zložitejších jazykov touto metódou je nad rámec tejto práce.

## Vstupy

Vstupné dátá sú zadané pomocou argumentov programu. Vstupom je jazyk, pre ktorý sa bude generovať reťazec. Ako argument 1 sa zadá reťazec symbolov jazyka a ako argument 2 sa zadá  $n$  - kolko krát sa má každý symbol v reťazci nachádzať.

Príklad vstupu:

```
$ ./re_grammar abc 3
```

## Výstupy

- Reťazec. Ak je tento reťazec rodiny, ktorú prijíma parser, tak je vytvorený súbor `success.txt` s týmto reťazcom.
- Vygenerované lineárne gramatiky, ktoré simulujú frázovú gramatiku.
- Derivačný strom, ktorý vznikol pri generovaní reťazca.

## Hlavný modul - `main.c`

Úlohou tohto modulu je spracovanie vstupných dát, prípadné vypísanie nápovedy a inicializácia základného modulu `re_grammar.c`.

## Frázová gramatika - `re_grammar.c`

Ako už bolo spomenuté v tejto časti je simulovaná frázová gramatika pomocou dvoch lineárnych gramatík.

Činnosť tejto gramatiky je popísaná pseudokódom 1. Ako môžeme vidieť na začiatok sa inicializujú tri zásobníky - zásobník pre kontrolný jazyk, pre prefix a pre sufix reťazca. Terminály sú postupne spracovávané gramatikou  $G$ .

---

### Algorithm 1 Frázová gramatika simulovalá dvomi regulovanými lineárnymi gramatikami

---

```
1: Input Terminály,  $n$ 
2: Inicializuj zásobníky  $\Xi$ , prefix, sufix
3:  $prvý \leftarrow$  pozícia prvého terminálu
4:  $posledný \leftarrow$  pozícia posledného terminálu
5: while  $prvý < posledný$  do
6:    $prefix, sufix, \Xi \leftarrow$  LINEARGRAMMARG( $n$ , prvý terminál, posledný terminál)
7:    $prvý \leftarrow prvý - 1$ 
8:    $posledný \leftarrow druhý - 1$ 
9:   if  $prvý = posledný$  then
10:     $sufix \leftarrow sufix +$  LINEARGRAMMARQ( $\Xi$ , terminál)
11:    $string \leftarrow ( reversal(prefix) + sufix )$ 
12:   return  $string$ 
```

---

Činnosť gramatiky  $G$  je zjednodušene popísaná pseudokódom 3. Táto gramatika  $G$  je regulovaná vstupným argumentom  $n$ , ktorý určuje, kolko krát sa má aplikovať pravidlo tvaru  $S \rightarrow terminal1 S terminal2$ , ktoré je vygenerované podľa vstupných terminálov. Aplikácia tohto pravidla predstavuje vkladanie  $terminal1$  na zásobník  $prefix$  a  $terminal2$  na zásobník  $sufix$ .

V prípade, že je volaná gramatika  $G$  `linearGrammarG()` prvý krát, pri každej aplikácii vloží identifikátor pravidla gramatiky  $Q$  na zásobník riadiaceho jazyka, ktorý bude slúžiť pre reguláciu druhej gramatiky  $Q$ .

---

**Algorithm 2** Lineárna gramatika  $G$ 


---

```

1: function LINEARGRAMMARG( $n$ , prvý terminál, posledný terminál))
2:   while  $n \neq 0$  do
3:     if Funkcia je volaná prvý krát then
4:        $\Xi \leftarrow 1$ 
5:       // aplikuj pravidlo 1 tvaru  $S \rightarrow$  prvý terminál  $S$  posledný terminál
6:        $prefix \leftarrow$  prvý terminál
7:        $sufix \leftarrow$  posledný terminál
8:        $n \leftarrow n - 1$ 
9:   return  $prefix, sufex, \Xi$ 
```

---

Ak je počet symbolov jazyka nepárny, teda aktuálne spracovaný terminál má index prvého a zároveň posledného, začne vykonávať svoju činnosť gramatika  $Q$ , ktorá generuje podreťazec reťazca a je implementovaná funkciou `linearGrammarQ()`.

Táto gramatika aplikuje svoje jediné pravidlo, dokiaľ zásobník s riadiacim jazykom nebude prázdny. Potom svoju činnosť ukončí, predá riadenie a vygenerovanú časť reťazca **RE** gramatike - `re_grammar()`.

---

**Algorithm 3** Lineárna gramatika  $Q$  regulovaná riadiacim jazykom  $\Xi$ 


---

```

1: function LINEARGRAMMARQ( $\Xi$ , terminál)
2:   while  $\Xi$  nie je prázdný do
3:      $sufix \leftarrow$  terminál
4:     Odstráň použité pravidlo z  $\Xi$ 
5:   return  $sufix$ 
```

---

### Tlač výstupu - `print_grammars.c`

Tento modul je pomocný. Obsahuje funkcie, ktoré sú volané v priebehu činnosti `re_grammar()`. Pomocou tohto modulu sa vypíšu vygenerované gramatiky a ich pravidlá, strom, ktorý vzniká pri generovaní reťazca a taktiež výstupný reťazec na štandardný výstup `STDOUT`.

## 8.2 Syntaktická analýza založená na regulovanom zásobníkom automate

Syntaktická analýza je implementovaná programom `parser`, ktorý pozostáva zo šiestich modulov. Dva z nich `stack.c` a `color_text.c` už boli zmienené a sú zdielané s programom `re_grammar`. Zvyšné štyri si popíšeme v tejto sekcií.

## Vstupy

Vstupné dátá sú zadané pomocou argumentov programu. Vstupom je reťazec, alebo súbor, ktorý obsahuje reťazec, ktorý bude analyzovaný.

Príklad vstupu:

```
$ ./parser aaabbbccc  
alebo  
$ ./parser -f string.txt
```

## Výstupy

- Proces akceptovania reťazca, zobrazené aplikované pravidlá, stav zásobníku, stav automatu a aktuálny symbol vstupnej pásky.
- Správa, či bol reťazec prijatý/zamietnutý.

## Hlavný modul - main.c

Úlohou tohto modulu je spracovanie vstupných dát, prípadné vypísanie nápovedy a inicializácia jadra tohto programu - modulu `pushdown_automata.c`.

## Regulovaný zásobníkový automat - pushdown\_automata.c

Jadrom celej syntaktickej analýzy je tento modul. Činnosť syntaktického analyzátoru je implementovaná zásobníkovým automatom regulovaným riadiacim lineárnym jazykom.

Tento zásobníkový automat má nasledujúcu štruktúru:

```
typedef struct {  
    char      PDA_state;  
    tStack2 PDA_stack;  
    tStack    PDA_control_language;  
} tPDA;
```

Na začiatku sa inicializuje zásobníkový automat a jeho zásobníky. Ako stav sa nastaví počiatočný stav  $s$ . Na zásobník sa vloží symbol značiaci dno zásobníku  $\$$  a počiatočný symbol  $S$ . Na zásobník sa aplikáciou lineárnej gramatiky vložia pravidlá  $12X5$ . Vstupný reťazec sa vloží na zásobník z dôvodu jednoduchšej manipulácie s reťazcom.

Akceptovanie reťazca prebieha v cykle. V každej iterácii sa aplikuje práve jedno pravidlo. Aplikácia prvého pravidla je implementovaná z dôvodu formálnej definície, ale prakticky nemá žiadnu významnejšiu funkčnosť. Aplikovaním tohto pravidla automat prejde do stavu  $q$ , vyjme použité pravidlo a začne so spracovaním vstupného reťazcu.

Zvyšná časť algoritmu je podrobne popísaná v [7.2](#) pri formálnom zostrojení automatu. Preto je k dispozícii v tejto sekcií stručnejší pseudokód [4](#).

## Pravidlá - rules.c

V tomto module sa nachádza päť implementovaných pravidiel, ktoré boli uvedené pri zostrojení automatu [7.2](#). V pseudokóde [4](#) môžeme vidieť stručný popis každého pravidla.

---

<sup>2</sup>Štruktúra `tStack` je implementovaná v module `stack.c`

## Tlač výstupu - print\_output.c

Tento modul je pomocný. Obsahuje funkcie, ktoré sú volané v priebehu činnosti `parser()`-a. Pomocou tohto modulu sa vypisuje prehľadná tabuľka, ktorá je generovaná počas akceptovania reťazca automatom.

---

### Algorithm 4 Zásobníkový automat regulovaný lineárnym jazykom

---

```
1: Vlož symbol dno zásobníku na zásobník
2: Vlož symbol štart symbol na zásobník
3: stav  $\leftarrow$  s
4:  $\Xi \leftarrow 12X5$ 
5: while not Koniec do
6:   Vyber pravidlo
7:   switch pravidlo do
8:     case 1
9:       stav  $\leftarrow$  q
10:    case 2
11:      while symbol na vstupnej páske = a do
12:        Vlož symbol zo vstupnej pásky na zásobník
13:        Odstráň symbol zo vstupnej pásky
14:         $\Xi \leftarrow 3X4$ 
15:        Aplikuj pravidlo 3:  $X \rightarrow \varepsilon$  na  $\Xi$ 
16:    case 3
17:      if symbol na vstupnej páske = b and TOP zásobníku = a then
18:        Vyjmi symbol a zo zásobníku
19:        Odstráň symbol zo vstupnej pásky
20:    case 4
21:      if symbol na vstupnej páske = c and TOP zásobníku = štart symbol then
22:        Odstráň štart symbol zo zásobníku
23:        Odstráň symbol zo vstupnej pásky
24:    case 5
25:      if Vstupná páska je prázdna then
26:        stav  $\leftarrow$  f
27:    default
28:      Koniec  $\leftarrow$  true
29:    Odstráň pravidlo
30: if dno zásobníka and stav = f and vstupná páska a  $\Xi$  sú prázdne then
31:   Syntaktická analýza úspešná
32: else
33:   Syntaktická analýza neúspešná
```

---

Demonštrácia a manuál tohto programu sa nachádzajú v prílohách **B** a **C**.

# Kapitola 9

## Záver

Cieľom bakalárskej práce bolo ukázať, že zásobníkové automaty, ktoré regulujú použitie pravidiel riadiacim jazykom je možné aplikovať v praxi a sú implementovateľné. Boli skúmané automaty, ktoré túto reguláciu riadia regulárnym jazykom, avšak táto regulácia nemá efekt na silu zásobníkového automatu. Táto práca bola predovšetkým zameraná na automaty regulované lineárnym jazykom. Implementácia a aplikácia bola vykonaná na jednoduchom jazyku, pretože analýza zložitejších jazykov je nad rámec tejto práce.

Mnou definovaný cieľ formálne zostrojiť a implementovať syntaktickú analýzu založenú na tejto metóde bol splnený.

K definovaniu a pochopeniu týchto automatov bolo nevyhnutné čitateľovi predstaviť teóriu formálnych jazykov, preto bol tento text členený hierarchicky. Na jednoduchý úvod teórie formálnych jazykov postupne navázovali zložitejšie definície. Bola stručne predstavená Chomského klasifikácia gramatík, ktorá nás sprevádzala celou prácou. Nevyhnutnosťou pre predstavenie regulovaných automatov bolo uviesť lineárne a ľavo rozšírené frontové gramatiky.

Po gramatikách, ktoré generujú daný jazyk boli uvedené automaty - zariadenia pre prijatie jazykov. Bol predstavený najjednoduchší konečný automat, automat rozšírený o zásobník a jeho verzie, medzi ktoré patria regulované automaty.

Uvedený bol základný typ týchto automatov a špeciálny automat - jedno-otáčkový atómický zásobníkový automat regulovaný lineárnym jazykom, ktorý počas svojej činnosti zväčšuje dĺžku zásobníka. V momente, keď nastane redukcia dĺžky zásobníka, automat vykoná *otáčku* a začne sa vyprázdňovať. V prípade ak sa už dĺžka nezväčší, automat je *jedno-otáčkový*. Klasické zásobníkové automaty regulované riadiacim jazykom môžu vykonať viac týchto *otáčok*. Sila týchto automatov je rovnaká, ale mechanizmus jedno-otáčkového automatu je jednoduchší.

Pre zostrojenie syntaktickej analýzy bolo potrebné popísť prekladač a jeho činnosť - preklad, ktorý prebieha v šiestich fázach, pričom bolo v tejto práci dôležité zamerať sa na syntaktickú analýzu.

Po teoretickej časti nasledovalo zostrojenie syntaktického analyzátoru založeného na zásobníkových automatoch regulovaným lineárnym jazykom. Bolo ukázané, že tieto automaty sú za silou normálneho zásobníkového automatu a, že prijímaný jazyk nie je bezkontextový ale rekurzívne vyčísliteľný.

Rekurzívne vyčísliteľné jazyky generuje frázová gramatiky, ktorú sme simulovali pomocou dvoch lineárnych gramatík. Pôvodnou ideou bolo implementovať simuláciu frázovej gramatiky a syntaktickú analýzu založenú na zásobníkovom automate, ktorý reguluje použitie lineárnym jazykom ako jeden program. Na začiatok by bol vygenerovaný reťazec pre jazyk

$a^n b^n c^n$  a následne by bol tento reťazec spracovaný syntaktickou analýzou. Pri implementácii ale vznikla myšlienka oddeliť tieto dva celky a implementovať ich ako dva navzájom nezávislé programy. Dôvodom bolo pozorovať, ako sa automat bude správať pri prijatí rôznych dĺžok reťazcov a v prípade prijatia reťazca, ktorý nie je syntakticky správny, teda obsahuje rôzny počet jednotlivých symbolov alebo dokonca symboly, ktoré sa v danom jazyku nenachádzajú.

Syntaktický analyzátor bol implementovaný automatom, ktorý je regulovaný jazykom. Tento jazyk generuje lineárna gramatika. Počas kontroly sekvencie prvého symbolu v reťazci, teda aplikácie pravidla automatu, táto gramatika aplikovala pravidlo na riadiaci jazyk. Po spracovaní prefixu reťazca bola vopred známa celá sekvencia pravidiel, ktoré majú byť použité. Práve vďaka tejto skutočnosti už nemuseli byť na zásobník symboly vkladané a aplikovali sa len pravidlá, ktoré dĺžku zásobníka redukovali. Čo je z implementačného hľadiska veľmi výhodné, kvôli rôznej spojenej s pridaním záznamov do pamäte.

Počas formálneho zstrojovania automatu regulovaného riadiacim lineárnym jazykom som zistila, že tento automat by pri tomto jednoduchom jazyku nepotreboval žiadne stavy. Takže by mohol mať o dve pravidlá menej a implementácia by bola tým pádom jednoduchšia. Nebolo by potrebné uchovávať stav, kontrolovať stav a prechádzať z jedného stavu do druhého. Pre reguláciu a akceptovanie tohto jazyka je regulovanie pravidla kontrolným jazykom postačujúce. Keďže riadiaci jazyk je vytvorený v priebehu akceptovania prvého symbolu, automat je regulovaný týmto jazykom a preto nie je možné aby sa automat dostal do iného stavu. Identifikátory pravidiel, ktoré sa nachádzajú v riadiacom jazyku by sme si mohli predstaviť ako stavy. Pri vhodnom zstrojení pravidiel by táto skutočnosť mohla platiť aj pri zložitejších jazykoch.

Zaujímavé by bolo skúmať zotavovanie sa z chýb behom syntaktickej analýzy založenej na tejto metóde. Predstavme si, žeby sa chyba nenachádzala hneď v prvej časti reťazca. Teda v tej časti, ktorá sa vkladá na zásobník a počas čoho sa generuje riadiaci jazyk. Tento jazyk určuje sekvenciu pravidiel, ktoré sa budú aplikovať. Takže po akceptovaní sekvencie prvého symbolu máme vopred známe, ako sa bude automat správať. V prípade, ak by nastala situácia, že niektoré pravidlo nie je aplikovateľné, pretože na vstupe je chyba, mohla by sa táto chyba jednoducho podľa tohto pravidla opraviť.

Simulácia frázovej gramatiky bola implementovaná všeobecne, pre jazyk, ktorý má neobmedzený počet symbolov, pričom každý symbol sa v reťazci nachádza práve  $n$ -krát. Ďalším možným pokračovaním tejto bakalárskej práce by bolo upraviť automat tak, aby na základe výstupu tejto metódy frázovej gramatiky - teda pravidiel jej dvoch lineárnych gramatík bol zstrojený automat, ktorý by bol schopný akceptovať všetky reťazce, ktoré táto gramatika generuje.

Takže si myslím, že má zmysel pokračovať v skúmaní tejto problematiky a analyzovaní značne komplexnejších jazykov s využitím zásobníkového automatu, ktorý je regulovaný lineárnym riadiacim jazykom.

# Literatúra

- [1] Češka, M.: *Teoretická informatika*. učební text FIT VUT v Brně, 2002.  
URL <http://www.fit.vutbr.cz/study/courses/TIN/public/Texty/ti.pdf>
- [2] Kolář, D.; Meduna, A.: Regulated Pushdown Automata. *Acta Cybernetica*, ročník 2000, č. 4, 2000: s. 653–664, ISSN 0324-721X.  
URL [http://www.fit.vutbr.cz/research/view\\_pub.php?id=6020](http://www.fit.vutbr.cz/research/view_pub.php?id=6020)
- [3] Meduna, A.: *Automata and Languages: Theory and Applications* [Springer, 2000]. Springer Verlag, 2005, ISBN 1-85233-074-0, 892 s.  
URL [http://www.fit.vutbr.cz/research/view\\_pub.php?id=6177](http://www.fit.vutbr.cz/research/view_pub.php?id=6177)
- [4] Meduna, A.; Kolář, D.: One-Turn Regulated Pushdown Automata and Their Reduction. *Fundamenta Informaticae*, ročník 2001, č. 21, 2001: s. 1001–1007, ISSN 0169-2968.  
URL [http://www.fit.vutbr.cz/research/view\\_pub.php?id=7035](http://www.fit.vutbr.cz/research/view_pub.php?id=7035)
- [5] Meduna, A.; Masopust, T.: Self-Regulating Finite Automata. *Acta Cybernetica*, ročník 18, č. 1, 2007: s. 135–153, ISSN 0324-721X.  
URL [http://www.fit.vutbr.cz/research/view\\_pub.php?id=8269](http://www.fit.vutbr.cz/research/view_pub.php?id=8269)
- [6] Meduna, A.; Zemek, P.: *Regulated Grammars and Automata*. Springer-Verlag New York, 2014, ISBN 978-1-4939-0368-9, 694 s.

## **Prílohy**

## **Zoznam príloh**

<b>A Obsah CD</b>	<b>39</b>
<b>B Demonštrácia programu</b>	<b>40</b>
<b>C Manuál</b>	<b>45</b>

## **Príloha A**

### **Obsah CD**

K práci je priložené doprovodné CD s nasledujúcou adresárovou štruktúrou:

- **zdrojovy\_kod/** – priečinok obsahuje zdrojové kódy implementácie syntaktického analyzátoru a implementácie frázovéj gramatiky v jazyku C.
- **pisomna\_praca/** – zdrojové súbory v L<sup>A</sup>T<sub>E</sub>Xu potrebné na vygenerovanie písomnej časti bakalárskej práce a taktiež výsledný PDF súbor.

## Príloha B

# Demonštrácia programu

### Generovania reťazca programom `re_grammar`

Výstup programu `re_grammar` môžeme vidieť na obrázkoch [B.1](#) a [B.2](#).

V prvej časti sa nachádza zápis jazyka, ktorý bol zadaný argumentami programu. V druhej časti je lineárna gramatika  $G$ , ktorá bola vygenerovaná na základe vstupu.

Následne je zobrazený priebeh generovania reťazca derivačným stromom. Pri generovaní prvého symbolu reťazca a posledného je taktiež vygenerovaný riadiaci jazyk (`CONTROL L`).

Ďalej je vygenerovaná gramatika  $Q$  a podreťazec, ktorý vznikol aplikáciou pravidiel tejto gramatiky, ktorú reguloval lineárny jazyk (`CONTROL L`).

V prípade, že vygenerovaný reťazec patrí jazyku  $L(M)$ , ktorý prijíma parser, program vytvorí textový súbor `success.txt` v ktorom sa nachádza tento reťazec.

Na obrázku [B.2](#) je možné vidieť činnosť len jednej gramatiky. Ak je počet terminálov párný reťazec generuje len jedna gramatika.

### Akceptovanie reťazca programom `parser`

Výstup programu `parser` môžeme vidieť na obrázkoch [B.3](#) a [B.4](#).

Výstup pozostáva z tabuľky, ktorá zobrazuje aktuálny symbol na zásobníku automatu, dĺžku zásobníku, stav automatu, aktuálny symbol, ktorý sa nachádza na vstupnej páske a pravidlo, ktoré bolo v aktuálnom kroku aplikované.

Na konci výstupu je vypísaný stav automatu a riadiaceho jazyka. Na obrázku [B.4](#) môžeme vidieť, že nám zostáva aplikovať posledné pravidlo riadiaceho jazyka (`CONTROL LANGUAGE`), ale toto pravidlo nie je možné aplikovať. Toto pravidlo slúži pre odstránenie zásobníkového symbolu  $S$  zo zásobníku a prevedenia automatu do finálneho stavu  $f$ . To však ale nie je možné aplikovať. Vstupná páska nie je prázdna. Syntaktická analýza je neúspešná, pretože tento automat prijíma jazyk finálnym stavom a prázdnym zásobníkom.

### Generovania príkladov `generate_examples.sh`

Pre vygenerovanie príkladov použitia týchto programov `re_grammar` a `parser` je pripravený skript `generate_examples.sh`. Tento skript generuje príklady do adresára `examples`. Volá programy `re_grammar` a `parser` s rôznymi argumentami. Výstup `STDOUT` presmerováva do textových súborov. V prípade ak neboli niektorí program skompilovaní, program skompliluje.

```

Terminál - lubica@lubica-Lenovo-Z580:~/re_grammar - + ×
lubica@lubica-Lenovo-Z580:~$ cd re_grammar
lubica@lubica-Lenovo-Z580:~/re_grammar$ ./re_grammar abc 3
|-----|
| RE Language L = { a^3 b^3 c^3 } |
|-----|
|-----|
| GRAMMAR G = (N, T, P, S), where |
|-----|
| N      = { S } |
| T      = { a,c} |
| P      = {     1: S --> aSc           } |
|-----|
| G generates string in the following way: |
|-----|
|-----|
| PREFIX    NONTERMINAL    SUFFIX    CONTROL L |
|          S                                     |
|-----|
| a         S         c         1 |
|-----|
| a         S         c         1 |
|-----|
| a         S         c         1 |
|-----|
|-----|
| GRAMMAR Q = (N, T, P, S), where |
|-----|
| N      = { S } |
| T      = { b } |
| P      = {     1: S --> Sb
|             2: S --> epsilon       } |
|-----|
| Regulated by linear control language: |
| {111} |
|-----|
| Generated SUBSTRING by grammar Q: |
| bbbb |
|-----|
|-----|
| GENERATED STRING by grammar G and Q: |
| aaabbccc |
|-----|
|-----|
| This program created success.txt, where is generated |
| string which can be accepted by Regulated Pushdown Automata. |
lubica@lubica-Lenovo-Z580:~/re_grammar$
```

Obr. B.1: Generovanie retázca, ktorý je vhodný ako vstup pre parser

```

Terminál - lubica@lubica-Lenovo-Z580:~/re_grammar - + ×
lubica@lubica-Lenovo-Z580:~/re_grammar$ ./re_grammar abcdef
2

If you want to simulate RE Grammar (Type 0) by TWO grammars
the number of terminals has to be ODD!

Output will be generated by one LINEAR GRAMMAR.

-----+
| RE Language L = { a^2 b^2 c^2 d^2 e^2 f^2 } |
|-----+
| GRAMMAR G = (N, T, P, S), where           |
|-----+
| N      = { S }                           |
| T      = { a,b,c,d,e,f}                 |
| P      = { 1: S --> asf,                |
|           2: S --> bSe,                |
|           3: S --> cSd                 } |
|-----+
| G generates string in the following way:  |
|-----+
          PREFIX    NONTERMINAL    SUFFIX    CONTROL L
          S

          |       |       |       |
          a       S       f       1
          |       |       |       |
          a       S       f       1
          |       |       |
          b       S       e
          |       |       |
          b       S       e
          |       |       |
          c       S       d
          |       |       |
          c       S       d
          |       |       |
          |       |       |
          |-----+
| GENERATED STRING by grammar G and Q:   |
| aabbccddeeff                            |
|-----+
lubica@lubica-Lenovo-Z580:~/re_grammar$

```

Obr. B.2: Reťazec generovaný jednou lineárnou gramatikou

```

Terminál - lubica@lubica-Lenovo-Z580:~/parser - + ×
lubica@lubica-Lenovo-Z580:~$ cd parser
lubica@lubica-Lenovo-Z580:~/parser$ ./parser aaabbbccc
=====
|String to analyze
|aaabbbccc
=====
|TOP OF |SIZE OF|STATE   |INPUT    | RULE
|PDA    |STACK   |          |TAPE     |
|=====|
| S    | 2      | s       | a        |
| S    | 2      | q       | a        | 1: Ss  --> q
| a    | 3      | q       | a        | 2: qa  --> aq
| a    | 4      | q       | a        | 2: qa  --> aq
| a    | 5      | q       | b        | 2: qa  --> aq
| a    | 4      | q       | b        | 3: aqb --> q
| a    | 3      | q       | b        | 3: aqb --> q
| S    | 2      | q       | c        | 3: aqb --> q
| S    | 2      | q       | c        | 4: qc  --> q
| S    | 2      | q       | c        | 4: qc  --> q
| S    | 2      | q       |          | 4: qc  --> q
| $    | 1      | f       |          | 5: Sq  --> f
|=====|
=====
|          Parsing SUCCESSFUL!
|=====
|PUSHDOWN:      $
|No. of symbols: 1
|TERMINALS: 0 |NTERMINALS: 0 |BOTTOM MARKER: 1
|=====
|STATE OF AUTOMATA:  f
|CONTROL LANGUAGE: { Empty }
|=====

lubica@lubica-Lenovo-Z580:~/parser$
```

Obr. B.3: Akceptovanie retázca, ktorý je syntakticky správny

```

Terminál - lubica@lubica-Lenovo-Z580:~/parser - + ×
lubica@lubica-Lenovo-Z580:~/parser$ ./parser aabbccc
=====
|String to analyze
|aabbccc
=====
|TOP OF |SIZE OF|STATE   |INPUT    | RULE
|PDA    |STACK   |          |TAPE     |
|-----
| S    | 2      | s       | a        |
| S    | 2      | q       | a        | 1: Ss  --> q
| a    | 3      | q       | a        | 2: qa  --> aq
| a    | 4      | q       | b        | 2: qa  --> aq
| a    | 3      | q       | b        | 3: aqb --> q
| S    | 2      | q       | c        | 3: aqb --> q
| S    | 2      | q       | c        | 4: qc  --> q
| S    | 2      | q       | c        | 4: qc  --> q
|-----|
|           !!! Parsing UNSUCCESSFUL !!!
|-----|
|PUSHDOWN:                      $S
|No. of symbols: 2
|TERMINALS: 0 |NETERMINALS: 1 |BOTTOM MARKER: 1
|-----|
|STATE OF AUTOMATA:    q
|CONTROL LANGUAGE: { 5 }
|-----|
lubica@lubica-Lenovo-Z580:~/parser$
```

Obr. B.4: Akceptovanie reťazca, ktorý nie je syntakticky správny

# Príloha C

## Manuál

Tento projekt sa skladá z dvoch častí.

1. **re\_grammar** Táto časť generuje reťazce rekurzívne vyčísliteľných jazykov tvaru:  
 $(symbol_1)^n(symbol_2)^n \dots (symbol_y)^n$ , kde  $n \geq 1$  a  $y \geq 2$ .
2. **parser** Program akceptuje reťazce rekurzívne vyčísliteľného jazyka:  
 $L(M) = \{a^n b^n c^n\}$ , kde  $n \geq 1$

Programy boli vyvýjané pod operačným systémom Linux, distribúcia Ubuntu 14.04.3 LTS. Boli skompilované, spustené a testované pod operačnými systémami Windows a Linux.

### Kompilácia

Programy sú dodané vo forme zdrojových kódov jazyka C, spolu so súborom **Makefile** (pre každý program vlastný). Na skompilovanie programov je potrebný program **make** a kompilátor **gcc**.

### Použitie programu **re\_grammar**

Vstupné dátá sú zadané pomocou argumentov programu. Vstupom je jazyk, pre ktorý sa bude generovať reťazec. Ako **argument 1** sa zadá reťazec symbolov jazyka a ako **argument 2** sa zadá  $n$  - kolko krát sa má každý symbol v reťazci nachádzať.

Príklad vstupu:

```
$ ./re_grammar abc 3
```

### Použitie programu **parser**

Vstupné dátá sú zadané pomocou argumentov programu. Vstupom je reťazec, alebo súbor, ktorý obsahuje reťazec, ktorý bude analyzovaný.

Príklad vstupu:

```
$ ./parser aaabbbccc  
alebo  
$ ./parser -f string.txt
```