

- Bezkontextové gramatiky a jazyky ...
- Derivační stromy
- Jednoznačnost a nejednoznačnost gramatik a jazyků
- Syntaxí řízený překlad ...
- 'Překlad' regulárních výrazů na konečné automaty
- Realizace levého průchodu derivačním stromem ...
- Zásobníkové automaty
- 
- Ukázka 2. zápočtové písemky

# Bezkontextové gramatiky

Aritmetické výrazy v abecedě

$\{ a, +, \times, (, ) \}$

Například:  $a + a \times a$ ,  $(a + a) \times a$

$\langle \text{EXPR} \rangle \longrightarrow a$

$\langle \text{EXPR} \rangle \longrightarrow \langle \text{EXPR} \rangle + \langle \text{EXPR} \rangle$

$\langle \text{EXPR} \rangle \longrightarrow \langle \text{EXPR} \rangle \times \langle \text{EXPR} \rangle$

$\langle \text{EXPR} \rangle \longrightarrow (\langle \text{EXPR} \rangle)$

$E \longrightarrow a \mid E + E \mid E \times E \mid (E)$

*Odvození (derivace)*, slova  $a + a \times a$ :

$E \Rightarrow E + E \Rightarrow a + E \Rightarrow a + E \times E \Rightarrow a + a \times E \Rightarrow a + a \times a$

*levá derivace, pravá derivace ...*



$E \Rightarrow E + E \Rightarrow E + E \times E \Rightarrow E + E \times a \Rightarrow E + a \times a \Rightarrow a + a \times a$

A ještě příklad derivace, která není ani levá ani pravá:

$E \Rightarrow E + E \Rightarrow E + E \times E \Rightarrow E + a \times E \Rightarrow a + a \times E \Rightarrow a + a \times a$

# Derivační strom

strom odvození (derivační strom)



Těmto různým stromům odpovídají různé levé derivace:

$$E \Rightarrow E + E \Rightarrow a + E \Rightarrow a + E \times E \Rightarrow a + a \times E \Rightarrow a + a \times a$$

$$E \Rightarrow E \times E \Rightarrow E + E \times E \Rightarrow a + E \times E \Rightarrow a + a \times E \Rightarrow a + a \times a$$

## *Bezkontextová gramatika*

$G = (\Pi, \Sigma, S, P)$  :

$\Pi$  ... konečná množina *neterminálů*,

$\Sigma$  ... konečná množina *terminálů* ( $\Pi \cap \Sigma = \emptyset$ ),

$S \in \Pi$  ... *počáteční neterminál*

$P$  ... konečná množina pravidel typu

$A \rightarrow \beta$ , kde  $A \in \Pi$ ,  $\beta \in (\Pi \cup \Sigma)^*$ .

Relace  $\Rightarrow$  (resp.  $\Rightarrow_G$ ) na  $(\Pi \cup \Sigma)^*$  :

$\gamma \Rightarrow \delta$  právě když  $\gamma = \mu_1 A \mu_2$ ,  $\delta = \mu_1 \beta \mu_2$ ,  $(A \rightarrow \beta) \in P$

$\Rightarrow^*$  ... refl. a tranz. uzávěr  $\Rightarrow$

Tedy  $\gamma \Rightarrow^* \delta \Leftrightarrow_{df}$  ex. posloupnost  $\mu_0, \mu_1, \dots, \mu_n$  tak, že

$\gamma = \mu_0 \Rightarrow \mu_1 \Rightarrow \dots \Rightarrow \mu_n = \delta$ .

(*Derivace* (délky  $n$ ) slova  $\delta$  ze slova  $\gamma$ .)

Jazyk generovaný gramatikou  $G$ :  $L(G) = \{ w \in \Sigma^* \mid S \Rightarrow^* w \}$

Jazyk  $L$  je bezkontextový  $\Leftrightarrow_{df}$  ex. BG  $G$  tak, že  $L(G) = L$ .

Značení:

$a, b, c, \dots$  ... terminály

$u, v, w, \dots$  ... řetězce terminálů

$A, B, C, \dots, X, Y, Z$  ... neterminály

$\alpha, \beta, \gamma, \dots$  ... řetězce neterminálů a terminálů

$\alpha \Rightarrow^L \beta$  (*levé přepsání*)  $\Leftrightarrow_{df}$

lze psát  $\alpha = uX\delta$  a  $\beta = u\gamma\delta$ , kde  $(X \rightarrow \gamma) \in P$   
( $u \in \Sigma^*$ ,  $\delta \in (\Pi \cup \Sigma)^*$ ).

$\alpha_0 \Rightarrow \alpha_1 \Rightarrow \dots \Rightarrow \alpha_n$  je *levou derivací*  $\Leftrightarrow_{df}$   $\alpha_i \Rightarrow^L \alpha_{i+1}$  ( $0 \leq i \leq n-1$ ).

*Derivační strom* (vztahující se ke  $G = (\Pi, \Sigma, S, P)$ ), je uspořádaný kořenový strom, v němž

- vrcholy ohodnoceny prvky  $\Pi \cup \Sigma$ ,
- kořen ohodnocen  $S$ ,
- vrchol ohodnocený  $X (\in \Pi)$  má následníky ohodnocené  $Y_1, Y_2, \dots, Y_n$  ( $Y_i \in \Pi \cup \Sigma$ ), kde  $(X \rightarrow Y_1 Y_2 \dots Y_n) \in P$ ,
- vrchol ohodnocený  $a (\in \Sigma)$  je listem.

Derivační strom pro  $w = a_1 a_2 \dots a_n \dots$  má listy zleva doprava ohodnoceny  $a_1, a_2, \dots, a_n$ .

**Věta.** Každému derivačnímu stromu pro slovo  $w$  (v dané gramatice  $G$ ) přirozeně odpovídá právě jedná levá derivace slova  $w$  (vyvozená z levého průchodu stromem); naopak každé levé derivaci slova  $w$  přirozeně odpovídá právě jeden derivační strom pro  $w$ .

Gramatika ovšem může sloužit **nejen** pro popis (**syntaxe**) jazyka; syntaktická struktura (derivační strom) konkrétního slova má obvykle sloužit **také** pro vyhodnocení **sémantiky** (významu) slova.

Tím významem může být např. hodnota z nějaké množiny (domény). Např. u dříve uvedených aritmetických výrazů je to (řekněmě přirozené) číslo.



Každému vrcholu derivačního stromu podle gramatiky

$$E \longrightarrow a \mid E + E \mid E \times E \mid (E)$$

můžeme přiřadit tento návod k výpočtu jeho hodnoty (tj. k výpočtu hodnoty podstromu, jehož je kořenem); návod závisí na označení vrcholu a jeho následníků:

- Je-li označen  $a$ , vydá hodnotu (číslo) přiřazené  $a$  (v této chvíli předpokládáme, že hodnota  $a$  byla už vyhodnocena dříve; teď je to pro nás elementární operace).
- Je-li označen  $E$  a následníci jsou označeni  $E, +, E$ , pak se vyhodnotí první a třetí následník a vydá se součet výsledných hodnot.
- Je-li označen  $E$  a následníci jsou označeni  $E, \times, E$ , pak se vyhodnotí první a třetí následník a vydá se součin výsledných hodnot.
- Je-li označen  $E$  a následníci jsou označeni  $(, E, )$ , pak se vyhodnotí druhý následník a jeho hodnota se vydá.
- Je-li označen  $(, ), +, \times$ , nevydává se žádná hodnota.

Pro úplnost si u těch aritmetických výrazů můžeme představit, že terminál  $a$  je nahrazen neterminálem  $A$  a jsou dodána pravidla

$$A \longrightarrow D \mid AD$$

$$D \longrightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$$

Jistě snadno dodáme pravidla pro vyhodnocení vrcholů derivačního stromu označených (terminálními) symboly  $0, 1, 2, \dots, 9$  a (neterminálními) symboly  $A, D$ .

Ale: lze si rozumně představit, že 'vyhodnocovač' (překladač) provádí dvě fáze (případně zároveň); ilustrujme např. na rozboru řetězce

$$25801 + 562 \times 803 + (9401 \times 82 + 65).$$

V první fázi přečte zadaný řetězec konečný automat, který najde a zahlásí každý výskyt celého čísla – takový výskyt je pro druhou fázi chápán jako jediný symbol (atom, terminál) s přiřazenou hodnotou onoho čísla.

Ve druhé fázi je konstruován derivační strom (syntaktická struktura) de facto pro řetězec  $a_1 + a_2 \times a_3 + (a_4 \times a_5 + a_6)$ .

(Symboly  $a_1, a_2, \dots, a_6$  jsou např. uloženy v tabulce, která udává i jejich přiřazené hodnoty  $25801, 562, \dots, 65$ .)

Tím jsme ilustrovali určitý **interpret**, který zadaný aritmetický výraz přečte a vydá jeho vypočtenou hodnotu.

Jinou možností je překladač (**kompilátor**); sémantika (cílový objekt) není v tomto případě číselná hodnota, ale např. program v jazyku nižší úrovně, který ji počítá.

Ilustrujme si takový překladač:

# Role bezkontextových gramatik při překladu

Překlad přiřazovacích příkazů typu

$$V := E$$
$$S \longrightarrow \langle id \rangle := E$$
$$E \longrightarrow \langle id \rangle \mid E + E \mid E * E \mid (E)$$

do assembleru

Instrukce	Efekt
LOAD $m$	$c(m) \rightarrow ACC$
STORE $m$	$c(ACC) \rightarrow m$
ADD $m$	$c(ACC) + c(m) \rightarrow ACC$
MPY $m$	$c(ACC) * c(m) \rightarrow ACC$
LOAD = $m$	$m \rightarrow ACC$
ADD = $m$	$c(ACC) + m \rightarrow ACC$
MPY = $m$	$c(ACC) * m \rightarrow ACC$

Např.  $Zisk := (Cena + Dan) * 0.12$

```
LOAD = 0.12 ;  
STORE $2 ;  
LOAD Dan ;  
STORE $1 ;  
LOAD Cena ;  
ADD $1 ;  
MPY $2 ;  
STORE Zisk
```

Práce překladače:

- lexikální analýza
- syntaktická analýza
- generování kódu

Důležité 'zotavení z chyb' (error recovery) zde pomíjíme.

Pro

$$Zisk := (Cena + Dan) * 0.12$$

je výsledkem lexikální analýzy

$$\langle id \rangle_1 := (\langle id \rangle_2 + \langle id \rangle_3) * \langle id \rangle_4$$


zároveň s tabulkou *TAB*:

Poř. číslo	Identifikátor	Informace
1	Zisk	prom. real
2	Cena	prom. real
3	Dan	prom. real
4	0.12	konst. real

Pro

$\langle id \rangle_1 := (\langle id \rangle_2 + \langle id \rangle_3) * \langle id \rangle_4$

je výsledkem syntaktické analýzy



# Pravidla pro 'vyhodnocení' vrcholů derivačního stromu

Vyhodnotit vrchol  $u$  znamená sestavit a vydat kód  $Cod(u)$



- $u$  ohodnocen  $\langle id \rangle_i$ :  
 $Cod(u)$  z  $TAB$  (např. pro  $\langle id_1 \rangle$  'Zisk', pro  $\langle id \rangle_4$  '= 0.12')
- $u$  ohodnocen  $:=, +, *$ :  $Cod(u)$  je prázdný
- $u$  s následníky  $u_1, u_2, u_3$  ohodnocen  $[S, n]$ :  $Cod(u)$  je  
'LOAD'  $Cod(u_3)$  ';' STORE'  $Cod(u_1)$
- $u$  s následníky  $u_1, u_2, u_3$  ohodnocen  $[E, n]$ , přičemž  $u_2$  ohodnocen  $+$ :  
 $Cod(u)$  je  
 $Cod(u_3)$  ';' STORE '\$'  $n$  ';' LOAD'  $Cod(u_1)$  ';' ADD '\$'  $n$
- podobně pro  $*$ :  $Cod(u)$  je  
 $Cod(u_3)$  ';' STORE '\$'  $n$  ';' LOAD'  $Cod(u_1)$  ';' MPY '\$'  $n$



# Nejednoznačné gramatiky

Existence dvou různých derivačních stromů (levých derivací) pro jedno a totéž slovo ... pro překlad (vyhodnocení sémantiky) závada!

Připomeňme si



u gramatiky

$$E \longrightarrow a \mid E + E \mid E \times E \mid (E)$$

# 'Opravená' (jednoznačná) gramatika (1. verze)

$$E \longrightarrow E + T \mid T$$


$$T \longrightarrow T \times F \mid F$$

$$F \longrightarrow (E) \mid a$$

Jediná levá derivace pro  $a + a \times a$ :

$$E \Rightarrow E + T \Rightarrow T + T \Rightarrow F + T \Rightarrow a + T \Rightarrow a + T \times F \Rightarrow a + F \times F \Rightarrow a + a \times F \Rightarrow a + a \times a$$

Jediný derivační strom pro  $a + a \times a$ :



# Jednoznačné gramatiky a jazyky

BG  $G$  je *jednoznačná*  $\Leftrightarrow_{df}$  každé slovo z  $L(G)$  má právě jednu levou derivaci (tj. právě jeden derivační strom).

V opačném případě je  $G$  *nejednoznačná* (či *víceznačná*).

Bezkontextový jazyk  $L$  je *jednoznačný*  $\Leftrightarrow_{df}$  ex. jednoznačná  $G$  tž.  $L(G) = L$ ; jinak se  $L$  nazývá (*vnitřně*) *nejednoznačný* (*víceznačný*).

Např.:

$L_1 = \{ a^n b^n \mid n \geq 0 \}$ :  $S \longrightarrow aSb \mid \varepsilon$  (je jednoznačný)

$L_2 = \{ a^i b^j c^k \mid (i = j) \vee (j = k) \}$ :

$S \longrightarrow S_1 C \mid AS_2$

$S_1 \longrightarrow aS_1 b \mid \varepsilon$        $S_2 \longrightarrow bS_2 c \mid \varepsilon$

$C \longrightarrow c C \mid \varepsilon$        $A \longrightarrow aA \mid \varepsilon$

Fakt: Neex. jednoznačná BG  $G$  tž.  $L(G) = L_2$ . ( $L_2$  je víceznačný.)

# 'Překlad' regulárních výrazů na konečné automaty

Omezme se na abecedu  $\Sigma = \{a, b\}$ . Množina regulárních výrazů nad  $\Sigma$  je dána např. gramatikou

$$R \longrightarrow \emptyset \mid \varepsilon \mid a \mid b \mid R + R \mid R \cdot R \mid R^* \mid (R)$$

Pravidla pro konstrukci konečného automatu použitelná na zadaný derivační strom jsou jasná: pro vrchol označený

- $\emptyset, \varepsilon, a, b$ : vydej příslušný (elementární) automat;
- $R$  s následníky  $R, +, R$ :  
sestav automat  $A_1$  pro 1. následníka,  $A_2$  pro 3. následníka, a pak sestav a vydej automat  $A$  pro  $L(A_1) \cup L(A_2)$ ;
- $R$  s následníky  $R, \cdot, R$ :  
sestav automat  $A_1$  pro 1. následníka,  $A_2$  pro 3. následníka, a pak sestav a vydej automat  $A$  pro  $L(A_1) \cdot L(A_2)$ ;
- $R$  s následníky  $R, ^*$ : sestav automat  $A_1$  pro 1. následníka, a pak sestav a vydej automat  $A$  pro  $L(A_1)^*$ ;
- $R$  s následníky  $(, R, )$ : vydej automat sestavený pro 2. následníka.

Předchozí návod lze zase chápat jako interpret (rovnou vydá příslušný automat); lze ovšem opět upravit na kompilátor – vydávající jen návod k sestavení výsledného automatu.

Všimněme si ale, že gramatika

$$R \longrightarrow \emptyset \mid \varepsilon \mid a \mid b \mid R + R \mid R \cdot R \mid R^* \mid (R)$$

není jednoznačná.

To lze vyřešit např. takto:

$$R \longrightarrow T + R \mid T$$

$$T \longrightarrow F \cdot T \mid F$$

$$F \longrightarrow F^* \mid (R) \mid \emptyset \mid \varepsilon \mid a \mid b$$

Zůstává ovšem důležitý problém: jak konstruovat derivační strom k zadanému řetězci ?

Vlastně nemusíme strom fyzicky zkonstruovat, stačí umět realizovat např. levý průchod oním stromem!

No jo, ale to jde přece pomocí zásobníku ('stacku'), ne?



## Ukázka 2. zápočtové písemky

Příklad 1 je zamýšlen asi na 15 minut. Bude prověřovat např. schopnost konstrukce jednoduché bezkontextové gramatiky (BG) či zásobníkového automatu (ZA), nebo převod BG na ZA, apod.

---

1. Navrhněte bezkontextovou gramatiku  $G$  tak, že  $L(G) = L_1 \cdot L_2$  kde

$$L_1 = \{w \in \{a, b\}^* \mid w \text{ obsahuje podřetězec } bab\}$$

$$L_2 = \{a^n u \mid u \in \{a, b\}^* \text{ a } 1 \leq n \leq \text{délka}(u) \leq 2n\}$$

Přitom použijte  $S$  jako počáteční neterminál, a dále neterminály  $A, B, C$ . Musíte navrhnout právě jedno pravidlo s  $S$  na levé straně; snažte se, aby jste použili celkově nejvýše 10 pravidel.

Každý z příkladů 2,3,4 je zamýšlen na 3-4 minuty a je hodnocen 1 bodem. Tyto příklady mají prověřit kratší formou něco z výše uvedeného a také např. znalost uzávěrových vlastností třídy bezkontextových jazyků, schopnost zařazení jazyků do (Chomského) hierarchie (regulární, bezkontextové neregulární, nebezkontextové), porozumění obecným operacím s jazyky apod.

---

2. Definujte použitím pojmu pravé odvození, co to znamená, že

- gramatika  $G$  (rozumí se bezkontextová) je víceznačná
  
- bezkontextový jazyk  $L$  je víceznačný



3. Vyjmenujte, které z daných jazyků ( $|w|$  označuje délku slova  $w$ ,  $|w|_a$  označuje počet výskytů symbolu  $a$  ve  $w$ ;  $w^R$  značí zrcadl. obraz slova  $w$ )

$$L_1 = \{w \in \{a\}^* \mid |w| \text{ je druhou mocninou celého čísla } \},$$

$$L_2 = \{0^m 1^n 0^m \mid n \leq m\},$$

$$L_3 = \{w \in \{a, b\}^* \mid |w|_a \text{ je dělitelné pěti } \},$$

$$L_4 = \{w \in \{a, b\}^* \mid w \text{ obsahuje podslovo } abba \text{ nebo končí } bbb\}$$

jsou regulární:

jsou bezkontextové, ale ne regulární:

nejsou bezkontextové:

---

4. Charakterizujte co nejjednodušeji jazyk  $\{a\}^* \setminus L$ , (kde  $\setminus$  označuje operaci levého kvocientu):

$$\{a\}^* \setminus L = \{w \mid \dots$$

a uveďte příklad jazyků  $L_1, L_2$ , kde  $\{a\}^* \setminus L_1 = L_1$  a  $\{a\}^* \setminus L_2 \neq L_2$ .