

# Referát č. 9 Chomského normální forma bezkontextových gramatik

Ivo Kostecký, kos0148

Při převodu bezkontextové gramatiky do Chomského normální formy se po odstranění pravidel typu  $A \rightarrow \epsilon$  provádí krok, který odstraňuje pravidla typu  $X \rightarrow Y$  (neterminál se přepisuje na neterminál). (Pak tedy dostaneme jen pravidla typu  $A \rightarrow \alpha$ , kde  $\alpha$  je terminál nebo  $|\alpha| \geq 2$ , přičemž generovaný jazyk se nezměnil.)

Na vhodném příkladu **ilustrujte algoritmus** odstraňující ona pravidla  $X \rightarrow Y$  a **ukažte jeho korektnost**.

## Chomského normální forma

Chomského normální forma je tvar či specifický způsob zápisu formální gramatiky.

### Definice

Je přímo v zadání, jinými slovy: Bezkontextová gramatika je v Chomského normální formě, jestliže každé její pravidlo je tvaru  $X \rightarrow YZ$  nebo  $X \rightarrow a$ , kde „ $X, Y, Z$ “ označují neterminální symboly a „ $a$ “ terminální symbol. *Tedy na levé straně je jeden neterminál, na pravé terminál nebo maximálně 2 další neterminály.*

### Tvar CHNF

- $A \rightarrow BC$  nebo
- $A \rightarrow \alpha$  nebo
- $S \rightarrow \epsilon$  (je povoleno, pokud gramatika generuje prázdný řetězec a zároveň se  $S$  nevyskytuje na pravé straně žádného pravidla)

kde  $A, B$  a  $C$  jsou neterminály,  $\alpha$  je terminál,  $S$  je startovní neterminál a  $\epsilon$  je prázdný řetězec, přičemž  $B$  ani  $C$  nemohou být startovacím neterminálem.

### Algoritmus

1. odstranění  $\epsilon$ -pravidel;
  - a. nahrazení  $\epsilon$  těmi terminály a neterminály, které by se tam mohly objevit a přidat je za stávající pravidla. Je třeba to provést důkladně a zahrnout všechny možné vzniknuvší kombinace!
2. odstranění jednoduchých pravidel;
  - a. samostatné neterminály v jednom znaku nahradit jejich přepisem
3. odstranění terminálů mimo  $A \rightarrow a$ ;
  - a. zavést substituci novým neterminálem za všechny terminály, které jsou součástí neterminálů, kromě osamocených terminálů nebo skupiny terminálů.
4. pohlcování neterminálních symbolů.
  - a. Všechny neterminály, které jsou delší než 2 znaky se musí zkrátit zavedením dalších substitucí. Ponechá se první znak a zbývající se substituují dalším neterminálem.
  - b. Výsledkem je sada pravidel ve tvaru  $X \rightarrow YZ$ , přičemž pro zjednodušení mohou být zapsána i za sebou se znakem „nebo“.

## Příklady

### Transformace bezkontextových gramatik

**Příklad 1:** Převedte následující bezkontextovou gramatiku do Chomského normální formy.

$$\begin{aligned} S &\rightarrow AbB \mid d \\ A &\rightarrow CA b \mid B \\ B &\rightarrow cSd \mid \epsilon \\ C &\rightarrow a \mid xd \end{aligned}$$

1. Odstraníme  $\epsilon$ -pravidla

$$\begin{aligned} S &\rightarrow AbB \mid d \mid Ab \mid bB \mid b \\ A &\rightarrow CA b \mid B \mid Cb \\ B &\rightarrow cSd \\ C &\rightarrow a \mid xd \end{aligned}$$

2. Odstraníme jednoduchá pravidla

$$\begin{aligned} S &\rightarrow AbB \mid d \mid Ab \mid bB \mid b \\ A &\rightarrow CA b \mid Cb \mid cSd \\ B &\rightarrow cSd \\ C &\rightarrow a \mid xd \end{aligned}$$

3. Odstraníme terminální symboly mimo pravidel typu

$$\begin{aligned} A &\rightarrow a \\ S &\rightarrow ADB \mid d \mid AD \mid DB \mid b \\ A &\rightarrow CAD \mid CD \mid ESF \\ B &\rightarrow ESF \\ C &\rightarrow a \mid GF \\ D &\rightarrow b \\ E &\rightarrow c \\ F &\rightarrow d \\ G &\rightarrow x \end{aligned}$$

4. Zkrátíme pravidla pohlcením neterminálních symbolů

$$\begin{aligned} S &\rightarrow AH \mid d \mid AD \mid DB \mid b \\ A &\rightarrow CJ \mid CD \mid EK \\ B &\rightarrow EK \\ C &\rightarrow a \mid GF \\ D &\rightarrow b \\ E &\rightarrow c \\ F &\rightarrow d \\ G &\rightarrow x \\ H &\rightarrow DB \\ J &\rightarrow AD \\ K &\rightarrow SF \end{aligned}$$

### Příklad převodu na Chomského NF

#### Původní gramatika

$$\begin{aligned} A &\rightarrow B \mid C \\ B &\rightarrow 0B1 \mid 01 \\ C &\rightarrow D \mid E \\ D &\rightarrow 1D0 \mid 1 \\ E &\rightarrow 0E \mid 0 \end{aligned}$$

#### Po odstranění $X \rightarrow Y$

$$\begin{aligned} A &\rightarrow 0B1 \mid 01 \mid 1D0 \mid 1 \mid 0E \mid 0 \\ B &\rightarrow 0B1 \mid 01 \\ C &\rightarrow 1D0 \mid 1 \mid 0E \mid 0 \\ D &\rightarrow 1D0 \mid 1 \\ E &\rightarrow 0E \mid 0 \end{aligned}$$

#### Po nahrazení terminálů

$$\begin{aligned} A &\rightarrow NBJ \mid NJ \mid JDN \mid 1 \mid NE \mid 0 \\ B &\rightarrow NBJ \mid NJ \\ D &\rightarrow JDN \mid 1 \\ E &\rightarrow NE \mid 0 \\ N &\rightarrow 0 \\ J &\rightarrow 1 \end{aligned}$$

#### Chomského normální forma

$$\begin{aligned} A &\rightarrow NA_1 \mid NJ \mid JA_2 \mid 1 \mid NE \mid 0 \\ A_1 &\rightarrow BJ \\ A_2 &\rightarrow DN \\ B &\rightarrow NB_1 \mid NJ \\ B_1 &\rightarrow BJ \\ D &\rightarrow JD_1 \mid 1 \\ D_1 &\rightarrow DN \\ E &\rightarrow NE \mid 0 \\ N &\rightarrow 0 \\ J &\rightarrow 1 \end{aligned}$$



## Použití

Pro pochopení formy je třeba mít představu o tom, čeho forma to je.

### Bezkontextové gramatiky

S bezkontextovými jazyky a gramatikami se hojně setkáváme při syntaktické analýze textu, třeba zdrojových kódů programovacích jazyků. Slovo „bezkontextová“ v názvu gramatiky znamená, že na levé straně každého pravidla stojí jeden neterminál bez sousedních symbolů (tedy není v „kontextu“).

$G = (\{VÝROK, PŘÍVLASTEK, PODMĚT, PŘÍSUDEK\}, \{malý, velký, pes, kocour, běží, leží, spí\}, VÝROK, P_{dále})$

1. **VÝROK** → **PŘÍVLASTEK** **PODMĚT** **PŘÍSUDEK**
2. **PŘÍVLASTEK** → *malý*
3. **PŘÍVLASTEK** → *velký*
4. **PODMĚT** → *pes*
5. **PODMĚT** → *kocour*
6. **PŘÍSUDEK** → *běží*
7. **PŘÍSUDEK** → *leží*
8. **PŘÍSUDEK** → *spí*

Nyní zkusíme vygenerovat nějaké výroky. Začneme u počátečního symbolu a postupně aplikujeme některé z možných pravidel:

1. **VÝROK**
2. **PŘÍVLASTEK** **PODMĚT** **PŘÍSUDEK** (použité pravidlo: 1)
3. *malý* **PODMĚT** **PŘÍSUDEK** (použité pravidlo: 2)
4. *malý pes* **PŘÍSUDEK** (použité pravidlo: 4)
5. *malý pes spí* (použité pravidlo: 8)

## Význam

Všechny bezkontextové jazyky lze generovat bezkontextovými gramatikami v jistém speciálním tvaru. Derivační stromy, příslušné k těmto gramatikám, pak mají jednotný tvar. Tato skutečnost usnadňuje cestu k závěrům v některých úvahách o bezkontextových jazycích. Příkladem je Chomského nebo Greibachova normální forma.

Převedení zápisu gramatiky do CHNF vede k vytvoření jednoznačného derivačního stromu. Gramatika  $G$  je jednoznačná, jestliže každé slovo z  $L(G)$  má právě jedno levé odvození (právě jeden derivační strom), jinak je víceznačná a jako takovou ji není možné vždy transformovat na ekvivalentní jednoznačnou gramatiku.

**Hlavní výhodou v Chomského normální formě je že, každé odvození řetězce  $s$  n písmeny má přesně  $2n - 1$  kroků, je tedy možné určit, zda je řetězec v jazyku všech derivací ve známém počtu operací.**

### Derivační strom

Derivační strom je v reprezentant syntaktické struktury slovního řetězce podle formální gramatiky. V derivačním stromě jsou vnitřní uzly označeny jako neterminály gramatiky, zatímco koncové uzly jsou označeny jako terminály. Derivační stromy mohou být využity pro generování nebo analýzu vět v přirozeném jazyce, stejně tak jako během zpracování počítačových jazyků.

**Vytváření derivačních stromů ze specificky formátované gramatiky vede na jednoznačné derivační stromy, což je velká výhoda pro porovnávání bezkontextových gramatik mezi sebou.**

## Důkaz

Nejprve věta 12.2.2 o odstranitelnosti  $\epsilon$  přechodů: Ke každé bezkontextové gramatice  $G$  lze sestavit ekvivalentní nevypouštějící gramatiku  $G'$  tž.  $L(G') = L(G) - \{\epsilon\}$ . *Důkaz ve skriptech str. 62.*

**Věta 12.3.2** Ke každé *bezkontextové gramatice*  $G$  lze sestavit gramatiku  $G'$  v *CHNF* tž.  $L(G') = L(G) - \{\varepsilon\}$ .

**Důkaz:** Podle věty 12.2.2 můžeme rovnou předpokládat, že  $G$  je nevypouštějící (jinak ji do této formy převedeme). Ukážeme, jak postupnou transformací  $G$  zkonstruujeme ekvivalentní gramatiku  $G'$  v *CHNF*.

Nejprve z gramatiky  $G$  odstraníme pravidla typu  $X \rightarrow Y$ :

Pro každý neterminál  $A$  zkonstruujeme množinu  $\mathcal{D}_A = \{B \mid A \Rightarrow^* B\}$ ; pak pro každé pravidlo  $B \rightarrow \alpha$ , kde  $B \in \mathcal{D}_A$  a  $\alpha$  není rovno jednomu neterminálu, přidáme pravidlo  $A \rightarrow \alpha$ . Nakonec odstraníme všechna pravidla typu  $X \rightarrow Y$ . Snadno lze ověřit, že generovaný jazyk zůstává zachován.

Dále pro každý terminál  $a$  zavedeme nový neterminál  $A_a$  a přidáme pravidlo  $A_a \rightarrow a$ . Pak na pravé straně každého pravidla  $X \rightarrow \alpha$ , kde  $|\alpha| \geq 2$ , nahradíme každý výskyt terminálu  $a$  neterminálem  $A_a$ .

Je zřejmé, že generovaný jazyk zůstává stále zachován; jediná pravidla porušující podmínku *CHNF* mohou být typu  $X \rightarrow Y_1 Y_2 \dots Y_n$ , kde  $n \geq 3$  ( $Y_i$  jsou samozřejmě neterminály).

Každé pravidlo uvedeného typu lze ovšem nahradit soustavou  $X \rightarrow Y_1 Z_1, Z_1 \rightarrow Y_2 Z_2, \dots, Z_{n-3} \rightarrow Y_{n-2} Z_{n-2}, Z_{n-2} \rightarrow Y_{n-1} Y_n$ , kde  $Z_1, Z_2, \dots, Z_{n-2}$  jsou nově přidané neterminály.

Opět je snadné se přesvědčit, že generovaný jazyk se nezmění a uvedenými změnami vzniklá gramatika  $G'$  je požadovanou gramatikou v *CHNF*.  $\square$

Jednoduše si lze představit důkaz jako problém grafu o 2 uzlech nad sebou. Pokud horní a spodní uzel rozdělím a vložím mezi ně uzel další, pak se zcela logicky nemění význam grafu, pouze je v něm více uzlů. Přesně stejný případ vytváří gramatika v Chomského normální formě, protože nemění význam a pouze dochází k přidání pravidel se specifickými vlastnostmi.

**Co se tím říká?** Nedochozí k porušení správnosti gramatiky, neboť důkaz odstranění  $\varepsilon$  přechodů se provádí výše, to je první zásah do konstrukce gramatiky: ve stručnosti se pouze přepisují symboly na nová umístění, ale jde jen komplikaci zápisu. Dalším porušením integrity by mohlo být přepisování pravidel neterminály, ale lze jistě souhlasit, že zavedením substituce nedochází ke změně významu původního výrazu a právě tato úprava se v průběhu převodu do *CHNF* odehrává. Intuitivně lze vyčíst, že v rámci algoritmu nedochází k modifikaci samotné gramatiky.

Zdroje:

- [https://cs.wikipedia.org/wiki/Chomského\\_normální\\_forma](https://cs.wikipedia.org/wiki/Chomského_normální_forma)
- <http://www.cs.vsb.cz/jancar/TEORET-INF/teoret-inf.pdf>
- <http://www.cs.vsb.cz/kot/down/ti2007/TI-text-20070410.pdf>
- <http://www1.osu.cz/home/habibal/kurzy/ytzi2.pdf>
- <http://voho.cz/wiki/formalni-gramatika/>
- <http://people.cs.clemson.edu/~goddard/texts/theoryOfComputation/9a.pdf>