

Relacja: klasy gramatyk - klasy automatów

Podstawowymi narzędziami abstrakcyjnymi do opisu języków formalnych są gramatyki i automaty. Gramatyka jest formalnie czwórką $G = (N, T, P, S)$, gdzie

- N - zbiór zmiennych syntaktycznych, inaczej zwanych symbolami nieterminalnymi (w skrócie nieterminalami)
- T - zbiór stałych, inaczej zwanych symbolami terminalnymi (w skrócie terminalami)
- P - zbiór reguł postaci $\alpha \rightarrow \beta$, inaczej zwanych produkcjami, gdzie:

$$\alpha \in (N \cup T)^+, \beta \in (N \cup T)^*.$$

- $S \in N$ - symbol początkowy gramatyki

Język $L(G)$ generowany przez G to zbiór słów nad alfabetem T które można otrzymać startując z S i stosując produkcje (reguły) gramatyki.

- **typu(0)** kombinatoryczne (bez ograniczeń)
- **typu (1)** kontekstowe, produkcje postaci $\alpha \cdot A \cdot \beta \rightarrow \alpha \cdot \gamma \cdot \beta$, gdzie $|\gamma| \geq 1$, $A \in N$.
Wyjątkiem mogą być produkcje $S \rightarrow \epsilon$, ale wtedy S nie może wystąpić po prawej stronie żadnej produkcji
- **typu(2)** bezkontekstowe, produkcje postaci $A \rightarrow \beta$ gdzie $A \in N$.
- **typu(3)** jednostronnie liniowe. W szczególności prawostronnie liniowe gdy produkcje postaci $A \rightarrow wB$ lub $A \rightarrow \epsilon$, gdzie $w \in T^*$, $A, B \in N$.

Lewostronnie liniowe definiujemy analogicznie.

Generowanie $L_1 = \{ a^k : k \text{ jest dodatnią potęgą } 2 \}$

$$S \rightarrow AaB, A \rightarrow AA, A \rightarrow C,$$

$$Ca \rightarrow aaC, CB \rightarrow B, B \rightarrow \epsilon$$

Przykład generacji:

$$\begin{aligned} S &\rightarrow AaB \rightarrow^* A^k aB \rightarrow^* C^k aB \\ &\rightarrow C^{k-1} a^2 C^1 B \rightarrow^* C^{k-2} a^4 C^2 B \\ &\rightarrow^* a^{2^k} C^k B \rightarrow^* a^{2^k}. \end{aligned}$$

Generowanie $L_2 = \{ a^n b^n c^n : n \geq 1 \}$

$$\begin{aligned} S &\rightarrow ABSc \mid Abc, & BA &\rightarrow CA, & CA &\rightarrow CB \\ CB &\rightarrow AB, & Bb &\rightarrow bb, & A &\rightarrow a \end{aligned}$$

Zauważmy, że $AB \rightarrow^* BA$, oraz

$$(AB)^k b \rightarrow^* A(BA)^{k-1} Bb \rightarrow^* A^k B^{k-1} b \rightarrow^* a^k b^k$$

Przykład generacji:

$$\begin{aligned} S &\rightarrow *ABSc \rightarrow^* (AB)^{n-1} Abc^n = \\ A(BA)^{n-1} bc^n &\rightarrow^* a(BA)^{n-1} bc^n \rightarrow^* a^n b^n c^n \end{aligned}$$

Produkcje postaci $\alpha \rightarrow \beta$, gdzie $|\alpha| \neq \epsilon$ oraz $|\alpha| \leq |\beta|$.

Fakt

Każda gramatyka kontekstowa nie używająca słowa pustego jest równoważna pewnej gramatyce monotonicznej i odwrotnie.

Ten sam język $L_2 = \{ a^n b^n c^n : n \geq 1 \}$.

$$S \rightarrow aBSc \mid abc \quad Ba \rightarrow aB \quad Bb \rightarrow bb.$$

Zauważmy, że $B^{n-1}b \rightarrow^* b^n$.

Mamy wyprowadzenie:

$$\begin{aligned} S &\rightarrow aBSc \rightarrow aBaBScc \rightarrow \rightarrow aBaBaBSccc \\ &\rightarrow aBaBaBabcccc \rightarrow^* (aB)^{n-1} abc^n \\ &a^n B^{n-1} bc^n \rightarrow^* a^n b^n c^n. \end{aligned}$$

Ogólnie automaty to abstrakcyjne modele algorytmu decyzyjnego. Zaletą i jednocześnie wadą automatów jest uproszczony model obliczeń.

Nieformalny opis automatu z pamięcią typu \mathcal{T} :

- automat *czyta* słowo wejściowe symbol po symbolu,
- ma skończoną liczbę stanów
- ma dodatkową pamięć typu \mathcal{T}
- język $L(A)$ słów *akceptowanych* przez automat składa się z ciągów po wczytaniu których, po pewnej liczbie kroków, automat znajdzie się w stanie *akceptującym*

Klasa automatów odpowiada rodzajowi dodatkowej pamięci \mathcal{T} :

- **typ (0)** maszyny Turinga
(pamięć \mathcal{T} = taśma)
- **typ (1)** liniowo ograniczone
(\mathcal{T} = taśma o długości liniowej)
- **typ (2)** stosowe, inaczej zwane “ze stosem”,
(\mathcal{T} = stos)
- **typ (3)** skończone ($\mathcal{T} = \emptyset$).

Może też być \mathcal{T} = kolejka (kolejki), licznik (liczniki).

Twierdzenie

Gramatyki typu i odpowiadają automatom typu i , dla $i = 0 \dots 3$.

Do opisu języka/słowa często używane są morfizmy (kodowania).
Morfizm to funkcja

$$h : \Sigma_1 \rightarrow \Sigma_2^*$$

Funkcja h rozszerza się automatycznie na wszystkie słowa,
zapisujemy tę funkcję tak samo, choć (czysto formalnie) jest to już
inna funkcja (rozszerzenie h):

$$h : \Sigma_1^* \rightarrow \Sigma_2^*$$

Rozszerzenie jest zdefiniowane tak aby zachodziło

$$h(xy) = h(x)h(y)$$

Zdefiniujmy **język równościowy**:

$$EQ(h, g) = \{ w \neq \varepsilon : h(w) = g(w) \}$$

Na przykład łatwo się opisuje za pomocą zbiorów równościowych język

$$L = \{w \in \{a, b\}^+ : \#_a(w) = 2 \cdot \#_b(w)\}$$

Weźmy:

$$h(a) = 11; h(b) = \varepsilon, g(a) = \varepsilon, g(b) = 1.$$

Wtedy $L = EQ(h, g)$. Języki równościowe, jako problemy decyzyjne, są bardzo trudne.

Problem odpowiedności Posta: sprawdzić czy $EQ(g, h) = \emptyset$ dla danych morfizmów g, h .

Twierdzenie

Problem odpowiedności Posta jest nierozstrzygalny.

Problem można zdefiniować inaczej. Dane są dwie listy słów:

$$(x_1, x_2, x_3, \dots, x_k), (y_1, y_2, y_3, \dots, y_k)$$

Pytamy czy istnieje niepusty ciąg $i_1, i_2, i_3, \dots, i_m$ taki, że

$$x_{i_1} x_{i_2} x_{i_3} \dots x_{i_m} = y_{i_1} y_{i_2} y_{i_3} \dots y_{i_m}$$

Taki ciąg $i_1, i_2, i_3, \dots, i_m$ nazywamy rozwiązaniem problemu.

Przykłady. Weźmy listy

$$(10, 011, 101), (101, 11, 011)$$

Wtedy problem nie ma rozwiązania. Dla list

$(1, 10111, 10), (111, 10, 0)$ mamy (krótkie) rozwiązanie

$x_2 x_1 x_1 x_3 = y_2 y_1 y_1 y_3$. Natomiast dla list: $(0, 1, 011), (1, 011, 0)$ istnieje rozwiązanie, ale najkrótsze ma długość $m = 75$.

Najpierw sprowadzamy problem do przypadku gdy rozwiązanie musi zaczynać się od $i_1 = 1$.

Wprowadzamy morfizmy $\alpha(s) = s*$, $\beta(s) = *s$.

Dla list

$$(x_1, x_2, \dots, x_k), (y_1, y_2, \dots, y_k)$$

Niech $*$ będzie nowym symbolem. Konstruujemy nowe listy:

$$(*\alpha(x_1), \alpha(x_1), \alpha(x_2), \alpha(x_3), \dots, \alpha(x_k), *)$$

$$(\beta(y_1), \beta(y_1), \beta(y_2), \beta(y_3), \dots, \beta(y_k), **)$$

Originalny system ma rozwiązanie wtw. gdy nowy ma zaczynające się od pierwszej pary. Udowodnimy że tak zmodyfikowany problem Posta jest nierozstrzygalny.

Przypuśćmy, że mamy gramatykę G typu (0) i chcemy sprawdzić czy $u \xrightarrow{G}^* v$. Dołączamy symbole $\#, \$$ do alfabetu. Tworzymy listę (x_i, y_i) par złożoną z kilku podlist.

(x_1, y_1) , gdzie $x_1 = \# \cdot u \cdot \#, y_1 = \#$ (a, a) dla każdego symbolu z $N \cup \{\#\}$.

(β, α) dla każdej produkcji $\alpha \rightarrow \beta$ gramatyki.

$(\$, \#v\$)$.

Wtedy zmodyfikowany problem odpowiedności Posta ma rozwiązanie zaczynające się od 1 wtw. gdy $u \xrightarrow{G}^* v$. Z nierozstrzygalności sprawdzania $u \xrightarrow{G}^* v$ wynika nierozstrzygalność problemu Posta.

Przypuśćmy, że jedyną regułą gramatyki typu (0) jest

$$ab \rightarrow ba$$

oraz

$$u = aabb, v = bbaa$$

Wtedy wyprowadzeniu $aabb \rightarrow^* bbaa$ odpowiada następujący system:

1	2	3	4	5	6
#aabb#	a	b	ba	\$	#
#	a	b	ab	#bbaa\$	#

Najkrótszym rozwiązaniem tego systemu, zaczynającym się od 1, jest ciąg indeksów:

1 2 4 3 6 4 4 4 6 3 4 2 5.

Twierdzenie

Problem jednoznaczności gramatyki bezkontekstowej jest nierozstrzygalny.

Twierdzenie

Problem pustości języka kontekstowego jest nierozstrzygalny.

W przeciwieństwie do poprzedniego faktu mamy:

Twierdzenie

Problem przynależności (ang. membership) do języka kontekstowego jest rozstrzygalny.