

JAO - lematy o "pompowaniu" dla języków bezkontekstowych

Gramatyka G ze zbiorem nieterminali N i zbiorem terminali T jest w postaci normalnej Chomsky'ego wtw gdy każda produkcja (reguła) gramatyki jest jednej z dwóch postaci

$$A \rightarrow BC, \text{ gdzie } A, B, C \in N;$$

$$A \rightarrow a, \text{ gdzie } A \in N, a \in T.$$

(Postać normalna jest wygodna w dowodach wykorzystujących drzewa wyprowadzenia, gdyż drzewa stają się prawie binarne).

Twierdzenie


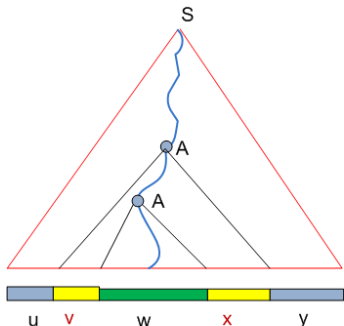
Jeśli $\epsilon \notin L(G)$ to można przekształcić G do postaci normalnej Chomsky'ego.

Transformacja polega na usunięciu symboli pustych z produkcji gramatyki oraz produkcji postaci $A \rightarrow B$. Produkcję postaci $A \rightarrow A_1A_2A_3 \dots A_k$, gdzie $A_i \in N$ zastępujemy przez zbiór:

$$A \rightarrow A_1D_1, D_1 \rightarrow A_2D_2, D_2 \rightarrow A_3D_3, \dots, D_{k-1} \rightarrow A_{k-1}A_k.$$

Lemat

Jeśli L bezkontekstowy, to dla $z \in L$ dostatecznie dużych (większych od pewnej stałej c) istnieje rozkład $z = uvwxy$, $vx \neq \epsilon$ spełniający $[(\forall i) uv^iwx^iy \in L] \ \& \ |vwx| \leq c$.



Z lematu o pompowaniu natychmiast wynika, że następujące języki nie są bezkontekstowe:

$$L1 = \{a^n b^n c^n : n \geq 1\}, \quad L2 = \{a^i b^j a^i b^j : i, j \geq 1\}$$

Nieskończony język nie zawierający słów postaci x^3 , nie jest bezkontekstowy (nie ma "pompowania"). Tak więc zbiory prefiksów/podsłów słowa Thue-Morse'a i Fibonacciego nie są bezkontekstowe ponieważ słowo \mathcal{T} nie zawiera x^3 , a słowo \mathcal{F} nie zawiera x^4 . Język $L3$ słów binarnych typu xx nie jest bezkontekstowy, gdyż

$$L3 \cap a^+ b^+ a^+ b^+ = L2$$

Dla $L = \{a^i b^j a^i b^k : k \geq 1\} \cdot \{a^k b^j a^i b^j : k \geq 1\}$ mamy $\sqrt{L} = L2$. Zatem operacja $\sqrt{\cdot}$ wyprowadza poza klasę języków bezkontekstowych.

Twierdzenie

Klasa języków bezkontekstowych nie jest zamknięta na dopełnienie i przecięcie teoriomnogościowe.

- Dopełnienie $L1$ jest bezkontekstowe, a $L1$ nie jest bezkontekstowy, dowodzi to niezamkniętości na dopełnienie.
- Języki $\{a^i b^j c^j : i, j \geq 1\}$, $\{a^j b^i c^i : i, j \geq 1\}$ są bezkontekstowe, ich przecięcie, równe $L1$, nie jest językiem bezkontekstowym:

$$L1 = \{a^i b^j c^j : i, j \geq 1\} \cap \{a^j b^i c^i : i, j \geq 1\}$$

Twierdzenie

Klasa języków bezkontekstowych jest zamknięta na operacje \cup , $$, $,$, konkatencję, odwracanie słów, oraz branie wszystkich przesunięć cyklicznych.*

Dla języka $a^*bc \cup \{a^pba^nca^n : p \text{ liczba pierwsza}, n \geq 1\}$ zwyczajny lemat o pompowaniu "nie chwyta", wzmocnijmy go.

Lemat (Lemat "o pompowaniu kontrolowanym", uproszczony lemat Ogdena)

Istnieje taka stała c , że jeśli zaznaczymy co najmniej c pozycji w słowie $z \in L$ to jedna z części pompujących (v, x w dekompozycji $uvwx$) zawiera wyróżnioną pozycję

Uzasadnienie. Tym razem rozważamy tylko **istotne** wierzchołki drzewa wyprowadzenia, tzn. te z których wychodzą co najmniej dwie różne krawędzie będące początkami ścieżek do liścia (pozycji w słowie terminalnym) wyróżnionego. Istnieje ścieżka na której są dwa *istotne* wierzchołki o tej samej etykiecie (nieterminalu). Teraz drzewo "pączkuje" tak jak poprzednio.

Lemat o pompowaniu kontrolowanym zastosujemy do języka

$$\{a^i b^j a^k : i \neq j \wedge i \neq k \wedge j \neq k\}$$

Niech c będzie stałą z lematu. Weźmy słowo $a^c b^c! a^{2c!}$.

Zaznaczamy prefiks długości c , wymuszamy by jedna z części pompujących była w pierwszej grupie liter a .

Podobnie dla języka

$$\{a^i b^j c^k : (i = j \text{ lub } j = k) \wedge i \neq k\}$$

Korzystając z Lematu Ogdena można udowodnić, że zbiór słów bez nietrywialnego okresu oraz jego dopełnienie nie są bezkontekstowe.

Natomiast język słów zawierających pewne pod słowo typu xx , $x \neq \epsilon$, dla alfabetu ternarnego, nie jest bezkontekstowy, ale nie widać jak wykorzystać tutaj lemat Ogdena.

Jednoznaczność języków bezkontekstowych

Gramatyka bezkontekstowa G jest jednoznaczna jeśli dla każdego słowa $w \in L(G)$ istnieje tylko jedno drzewo wyprowadzenia w tej gramatyce.

Na przykład gramatyka dla D_1 :

$$S \rightarrow (S) \mid SS \mid ()$$

jest niejednoznaczna, natomiast jest jednoznaczna gramatyka:

$$S \rightarrow (S) \mid (S)S \mid ()$$

Język bezkontekstowy nazywamy jednoznaczny jeśli jest generowany przez pewną gramatykę jednoznaczną.

Tak więc język D_1 jest językiem jednoznaczny (jak również języki nawiasowe D_k z k typami nawiasów).

Twierdzenie

Język $\{ a^i b^j c^j : i, j \geq 1 \} \cup \{ a^i b^j c^j : i, j \geq 1 \}$ jest niejednoznaczny.


Stosujemy takie rozumowanie jak w dowodzie lematu o pompowaniu kontrolowanym. Przypuśćmy, że gramatyka jednoznaczna G generuje nasz język, niech p będzie stałą z lematu. Weźmy słowo $a^p b^p c^{p+p!}$ i wyróżnijmy wszystkie a . Wtedy pierwsza część pompująca musi być w bloku a (na rysunku żółta), a druga w bloku symboli b (czerwony na rysunku). Po *podpompowaniu* otrzymujemy wyprowadzenie słowa $a^{p+p!} b^{p+p!} c^{p+p!}$ w którym pewne poddrzewo T_1 zaczyna się w bloku liter a i w bloku liter b , nie dalej niż p symboli od prawego końca tego bloku (kolor czerwony).

Dowód twierdzenia o niejednoznaczności

Stosując symetryczne rozumowanie dla słowa $a^{p+p!} b^p c^p$, w którym wyróżniamy ostatni blok, otrzymamy drzewo wyprowadzenia słowa

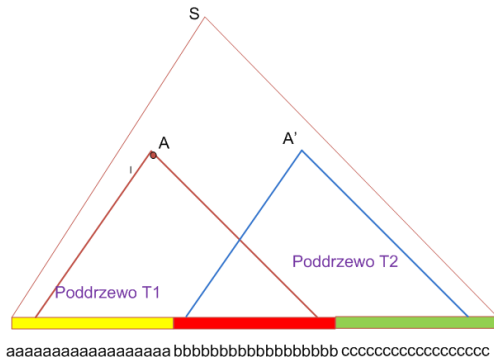
$$a^{p+p!} b^{p+p!} c^{p+p!}$$

w którym pewne poddrzewo T_2 zaczyna się w bloku liter b , nie dalej niż p pozycji od lewego końca tego bloku, a kończy w bloku liter c .



Niejednoznaczność

Drzewa T_1 , T_2 nie mogą być poddrzewami tego samego drzewa, ponieważ się *przecinają* (patrz rysunek). Zatem mamy więcej niż jedno drzewo wyprowadzenia (niejednoznaczność).



Twierdzenie Parikha dla języków bezkontekstowych

Przypomnienie: Ψ jest funkcją Parikha. Następujące twierdzenie jest również konsekwencją własności *pompujących* dla języków bezkontekstowych.

Twierdzenie

Jeśli L jest językiem bezkontekstowym to istnieje język R regularny taki, że $\Psi(L) = \Psi(R)$.

(Szkic dowodu)

Założmy, że gramatyka bezk. G jest w postaci normalnej Chomsky'ego i ma k nieterminali.

Niech N będzie taką stałą, że w każdym drzewie wyprowadzenia słowa długości co najmniej N istnieje ścieżka na której pewien nieterminal pojawia się co najmniej $k + 2$ razy.

Szkic dowodu twierdzenia Parikha

Niech Q będzie podzbiorem zbioru nieterminali i niech L_Q będzie zbiorem słów mających drzewo wyprowadzenia zawierające dokładnie wszystkie nieterminale z Q i żadnych innych.

Niech F_Q będzie zbiorem słów z L_Q o długości co najwyżej N , a T_Q będzie zbiorem słów xy takich, że $|xy| \leq N$ oraz istnieje wyprowadzenie $A \rightarrow^* xAy$ w którym występują jedynie nieterminale z Q . Wtedy

$$\Psi(L_Q) = \Psi(F_Q T_Q^*)$$

Zatem $L_Q = \bigcup_Q L_Q$ jest w sensie Parikha równoważny językowi który jest regularny, gdyż zbiory F_Q i T_Q są skończone.

Mamy

$$\Psi(L) = \bigcup_Q \Psi(F_Q T_Q^*)$$

Lemat

Jeśli L jest liniowym językiem bezkontekstowym, to dla $z \in L$ dostatecznie dużych (większych od pewnej stałej c) istnieje rozkład $z = uvwxy$, $vx \neq \epsilon$ spełniający

$$[(\forall i) uv^iwx^iy \in L] \ \& \ |uvxy| \leq c$$

Części pompujące są blisko brzegów słowa. Wynika stąd

Fakt

Istnieją języki bezkontekstowe, które nie są liniowe, na przykład język

$$\{ a^i b^i a^j b^j : i, j \geq 1 \}$$