



AKADEMIA GÓRNICZO-HUTNICZA
IM. STANISŁAWA STASZICA W KRAKOWIE

Łańcuchy i zbiory łańcuchów

Teoria automatów i języków formalnych

Dr inż. Janusz Majewski
Katedra Informatyki



Symbol, alfabet, łańcuch

Symbol

Symbol jest to pojęcie niedefiniowane (synonimy: znak, litera)

Alfabet

Alfabet jest to niepusty, skończony zbiór symboli, np.:

$\Sigma_1 = \{a, b, c, \dots, x, y, z\}$ - alfabet łaciński

$\Sigma_2 = \{0, 1\}$ - alfabet binarny

Niech Σ będzie alfabetem

$\Sigma \neq \emptyset; \quad \#\Sigma < \infty$

Łańcuch

łańcuch (synonim słowo) to skończony ciąg zestawionych razem symboli z alfabetu.

Rekurencyjna definicja łańcucha nad alfabetem Σ :

- 1) ε jest łańcuchem nad Σ (ε - łańcuch pusty, nie zawierający żadnego znaku),
- 2) jeśli x jest łańcuchem nad Σ i $a \in \Sigma$ to xa jest łańcuchem nad Σ ,
- 3) nic innego nie jest łańcuchem poza tym, co wynika z punktów (1) i (2).



Złożenie łańcuchów

Konkatenacja (złożenie) łańcuchów

Jeśli x i y są łańcuchami

$$x = x_1x_2\dots x_m$$

$$y = y_1y_2\dots y_n$$

to

$$xy = x_1x_2\dots x_my_1y_2\dots y_n$$

jest nazywane konkatenacją (złożeniem) łańcuchów x i y .

Przykład:

$$x = ab$$

$$y = cde$$

$$xy = abcde$$

Dla dowolnego łańcucha x zachodzi

$$x\varepsilon = \varepsilon x = x$$

Konkatenacja łańcuchów jest:

- nieprzemienne (na ogół $xy \neq yx$)
- łączna ($xyz = (xy)z = x(yz)$)
- posiada element neutralny ε będący łańcuchem pustym ($x\varepsilon = \varepsilon x = x$)



Rewers łańcucha

Rewersem (odbiciem zwierciadlanym) x^R łańcucha $x = x_1x_2\dots x_n$ nazywamy łańcuch $x^R = x_nx_{n-1}\dots x_1$, w którym symbole zapisane są w odwrotnym porządku, przy czym $\varepsilon^R = \varepsilon$.

Definicja rekurencyjna odbicia zwierciadlanego:

- 1) $\varepsilon^R = \varepsilon$,
- 2) jeśli x jest łańcuchem nad alfabetem Σ , zaś a jest symbolem ($a \in \Sigma$), to $(ax)^R = x^Ra$,
- 3) nic innego nie jest odbiciem zwierciadlanym poza tym, co wynika z punktów (1) i (2).



Palindrom

Palindromem nazywamy łańcuch, który czytany od przodu oraz czytany wspak brzmi tak samo, czyli $x^R = x$

Definicja rekurencyjna palindromu:

- 1) ε jest palindromem,
- 2) jeśli a jest symbolem ($a \in \Sigma$), to łańcuch zbudowany z pojedynczego symbolu a jest palindromem,
- 3) jeśli x jest palindromem, zaś a jest symbolem ($a \in \Sigma$), to łańcuch axa jest palindromem,
- 4) nic innego nie jest palindromem poza tym, co wynika z punktów (1), (2) i (3).

Przykłady palindromów: oko, kajak, kobyłamamałybok.



Notacja potęgowa, długość łańcucha

Notacja „potęgowa”

Niech a będzie symbolem. Niech x będzie łańcuchem. Wtedy łańcuchy złożone z wielokrotnych powtórzeń symbolu a lub łańcucha x oznaczamy w uproszczeniu:

$a^0 = \varepsilon$	$x^0 = \varepsilon$
$a^1 = a$	$x^1 = x$
$a^2 = aa$	$x^2 = xx$
$a^3 = aaa, \dots, \text{itd.}$	$x^3 = xxx, \dots, \text{itd.}$

Długość łańcucha

Długość $|x|$ łańcucha x to liczba symboli tworzących ten łańcuch.

Definicja rekurencyjna długości łańcucha:

- 1) $|\varepsilon| = 0$,
- 2) jeśli x jest łańcuchem, zaś a jest symbolem ($a \in \Sigma$), to $|ax| = 1 + |x|$.



Złożenie zbiorów łańcuchów (1)

Niech U_1 i U_2 będą zbiorami łańcuchów nad alfabetami odpowiednio Σ_1 i Σ_2 .
Złożeniem U_1U_2 tych zbiorów jest zbiór zawierający łańcuchy postaci x_1x_2 ,
gdzie $x_1 \in U_1$, zaś $x_2 \in U_2$.

$$U_1U_2 = \{ x_1x_2 \mid x_1 \in U_1, x_2 \in U_2 \}$$

Na ogół wygodnie jest utożsamić alfabet ze zbiorem łańcuchów o długości równej jeden każdy, czyli zawsze, gdy nie będzie to budzić wątpliwości, będziemy tak samo oznaczać alfabet i zbiór łańcuchów jednosymbolowych, np.:

$\Sigma = \{ a, b, c \}$ – alfabet, zbiór symboli

$\Sigma = \{ a, b, c \}$ – zbiór łańcuchów jednoliterowych

Złożenie zbiorów łańcuchów jest:

- nieprzemienne (na ogół $U_1U_2 \neq U_2U_1$)
- łączne ($U_1U_2U_3 = (U_1U_2)U_3 = U_1(U_2U_3)$)
- posiada element neutralny $\{\varepsilon\}$ będący zbiorem jednoelementowym, którego jedynym elementem jest łańcuch pusty ($U\{\varepsilon\} = \{\varepsilon\}U = U$)



Złożenie zbiorów łańcuchów (2)

Przykład składania zbiorów łańcuchów:

$$\Sigma_1 = \{ a, b \}$$

$$\Sigma_2 = \{ a, b, n, r \}$$

$$U_1 = \{ a, ba \}$$

$$U_2 = \{ rnaba, rab \}$$

$$U_1U_2 = \{ arnaba, barnaba, arab, barab \}$$

$$U_2U_1 = \{ rnabaa, rnababa, raba, rabba \}$$



Zbiór słownikowy (1)

Zbiór wszystkich łańcuchów nad alfabetem

Zbiór wszystkich łańcuchów nad alfabetem Σ oznaczamy Σ^* .

Zbiór wszystkich niepustych łańcuchów nad alfabetem Σ oznaczamy Σ^+ .

Przykład:

$$\Sigma = \{0, 1\}$$

$$\Sigma^* = \{ \epsilon, 0, 1, 00, 01, 10, 11, 000, 001, \dots \}$$

$$\Sigma^+ = \{ 0, 1, 00, 01, 10, 11, 000, 001, \dots \}$$



Zbiór słownikowy (2)

Formalnie stosując notację „potęgową” i wykorzystując definicję złożenia zbiorów łańcuchów mamy dla alfabetu Σ definicję rekurencyjną:

$$\Sigma^0 = \{\epsilon\}$$

$$\Sigma^1 = \Sigma = \{ x \mid x \text{ jest słowem nad } \Sigma, |x| = 1 \}$$

$$\Sigma^2 = \Sigma^1 \Sigma$$

.....

$$\Sigma^n = \Sigma^{n-1} \Sigma = \{ x \mid x \text{ jest słowem nad } \Sigma, |x| = n \}$$

$$\Sigma^* = \Sigma^0 \cup \Sigma^1 \cup \Sigma^2 \cup \Sigma^3 \cup \dots$$

$$\Sigma^+ = \Sigma^1 \cup \Sigma^2 \cup \Sigma^3 \cup \dots$$

$$\Sigma^+ = \Sigma \Sigma^*$$



Uporządkowanie zbioru słownikowego (1)

Niech \leq będzie relacją liniowego porządku na zbiorze (alfabecie) Σ .

Przykład: $\Sigma = \{a, b, c, d\}$. Uporządkowanie „alfabetyczne”: $a < b$; $a < c$; $a < d$; $b < c$; $b < d$; $c < d$

Zdefiniujemy relację \leq_s określoną na Σ^* . Powiemy, że $x = a_1 a_2 \dots a_m$ jest w relacji \leq_s z $y = b_1 b_2 \dots b_n$ ($x \leq_s y$; $x, y \in \Sigma^*$; $a_i, b_j \in \Sigma$ dla $1 \leq i \leq m$, $1 \leq j \leq n$), gdy spełniony jest jeden z dwóch poniższych warunków:

- $m < n$,
- $m = n$ oraz $a_i < b_i$ dla pewnego $i \leq m = n$ oraz $a_j = b_j$ dla wszystkich $1 \leq j < i$.

Relacja \leq_s jest quasi-porządkiem, który w zbiorze Σ^* definiuje porządek \leq_s nazywamy porządkiem standardowym. (Σ^*, \leq_s) jest zbiorem dobrze uporządkowanym.

Przykład: $\Sigma = \{a, b\}$. Porządek alfabetu: $a < b$. Zbiór słownikowy Σ^* w porządku standardowym:

$$\Sigma^* = \{\epsilon, a, b, aa, ab, ba, bb, aaa, aab, aba, abb, baa, bab, \dots\}$$



Uporządkowanie zbioru słownikowego (2)

Niech \leq będzie relacją liniowego porządku na zbiorze (alfabecie) Σ .

Zdefiniujemy relację \leq_L określoną na Σ^* . Powiemy, że $x = a_1 a_2 \dots a_m$ jest w relacji \leq_L z $y = b_1 b_2 \dots b_n$ ($x \leq_L y$; $x, y \in \Sigma^*$; $a_i, b_j \in \Sigma$ dla $1 \leq i \leq m$, $1 \leq j \leq n$, $k = \min(m, n)$), gdy spełniony jest jeden z dwóch poniższych warunków:

- (1) $a_i < b_i$ dla pewnego $i \leq k$ oraz $a_j = b_j$ dla wszystkich $1 \leq j < i$
- (2) $m < n$ oraz $a_i = b_i$ dla wszystkich $1 \leq i \leq m = k$.

Relacja \leq_L jest quasi-porządkiem, który w zbiorze Σ^* definiuje porządek \leq_L , który nazywamy porządkiem leksykograficznym. (Σ^*, \leq_L) jest zbiorem liniowo uporządkowanym. Nie jest on jednak zbiorem dobrze uporządkowanym.



Uporządkowanie zbioru słownikowego (3)

Przykład: $\Sigma = \{a, b\}$. Porządek alfabetu: $a < b$. Kilka pierwszych elementów zbioru słownikowego Σ^* w porządku leksykograficznym:

$$\Sigma^* = \{\varepsilon, a, aa, aaa, aaaa, aaaaa, \dots\}$$

Dlaczego uporządkowanie leksykograficzne nie jest porządkiem dobrym? Weźmy nieskończony podzbiór zbioru Σ^* : $\{b, ab, aab, aaab, aaaab, \dots\}$. Elementy tego podzbioru są uporządkowane malejąco:

$$b \succ_L ab \succ_L aab \succ_L aaab \succ_L aaaab \succ_L \dots$$

Oczywiście podzbiór ten nie ma elementu najmniejszego, uporządkowanie leksykograficzne nie jest więc porządkiem dobrym. Porządek leksykograficzny w nieskończonym zbiorze Σ^* jest bardzo skomplikowany i trudno go sobie wyobrazić.



Uporządkowanie zbioru słownikowego (4)

Porządek leksykograficzny jest jednak powszechnie wykorzystywany do skończonych zbiorów łańcuchów, np. do określania kolejności słów w encyklopediach, słownikach, leksykonach. Wówczas quasi-porządek \prec jest powszechnie przyjętym uporządkowaniem liter w alfabecie pewnego języka naturalnego.

Ponieważ dla zbioru słownikowego Σ^* można określić porządek liniowy (np. leksykograficzny) lub porządek dobry (np. standardowy), można więc wszystkie elementy zbioru słownikowego ułożyć w ciąg i ponumerować. Świadczy to o równoliczności zbioru słownikowego ze zbiorem liczb naturalnych.



Uporządkowanie zbioru słownikowego (5)

Numeracja Gödla: Można ponumerować elementy zbioru słownikowego:

- numerujemy elementy alfabetu $\Sigma = \{a_1, a_2, \dots, a_n\}$
- niech $p_1 p_2 p_3 p_4 \dots$ będzie ciągiem rosnącym liczb pierwszych, np. 2, 3, 5, 7, ...
- określamy funkcję $num(x)$ dla $x \in \Sigma^*$

$$num(\varepsilon) = 0$$

$$num(a_{i_1} a_{i_2} \dots a_{i_k}) = \prod_{j=1}^k p_j^{i_j}$$

Można pokazać, że odwzorowanie

$$num: \Sigma^* \mapsto \mathbf{N}$$

jest wzajemnie jednoznaczne (funkcja $num(x)$ jest różnowartościowa).

Przykład:

$\Sigma = \{a, b\}$, numerujemy litery $\Rightarrow \Sigma = \{a_1, a_2\}$

określamy rosnący ciąg liczb pierwszych: p_1, p_2, p_3, \dots jako 2, 3, 5, 7, ...

analizujemy słowo $x = abaa \in \Sigma^*$, $x = a_1 a_2 a_1 a_1$,

$$num(x) = p_1^1 \cdot p_2^2 \cdot p_3^1 \cdot p_4^1 = 2^1 \cdot 3^2 \cdot 5^1 \cdot 7^1 = 2 \cdot 9 \cdot 5 \cdot 7 = 630$$