

Algorytmy tekstowe: pojęcia

Σ - skończony niepusty zbiór symboli zwany *alfabetem*. Dowolny ciąg symboli ze zbioru Σ nazywamy *słowem (nad alfabetem Σ)*.

Przykład. *abba* jest słowem nad alfabetem $\Sigma = \{a, b\}$.

Przez ϵ oznaczamy *słowo puste*.

Przez Σ^* oznaczamy (nieskończony) zbiór wszystkich słów nad alfabetem Σ .

Przez $|w|$ będziemy oznaczać *długość słowa w* , np.
 $|abba| = 4, |\epsilon| = 0$.

Algorytmy tekstowe: pojęcia cd.

Konkatenacja słów u i v jest to słowo uv powstałe po dopisaniu słowa v za słowem u .

Słowo w jest prefiksem słowa u , jeśli $u = wv$ dla pewnego słowa v .

Słowo w jest sufiksem słowa u , jeśli $u = vw$ dla pewnego słowa v .

Przykłady.

- *te jest prefiksem słowa $teksty$; $ksty$ jest jego sufiksem.*
- *ϵ jest prefiksem i sufiksem każdego słowa.*
- *Każde słowo jest swoim własnym prefiksem i sufiksem.*

Jeśli w jest prefiksem u , ale $w \neq u$ to mówimy, że w jest właściwym prefiksem u .

Analogicznie definiujemy właściwy sufiks.

Problem wyszukiwania wzorca

Dane: słowa p („wzorzec”) i t („tekst”) nad pewnym alfabetem Σ .

$$|p| = m, |t| = n, |p| \leq |t|.$$

Problem: znaleźć wszystkie wystąpienia wzorca p w tekście t .

Przykład: wzorzec xy występuje w tekście $xyyxyxy$ na pozycjach 2, 5 i 7.

Algorytm „naiwny”

Próbujemy dopasować wzorzec we wszystkich miejscach:

```
1:  $i \leftarrow 1$ 
2: while  $i \leq n - m + 1$  do
3:    $j \leftarrow 0$ 
4:   while  $p[j + 1] = t[i + j]$  do
5:      $j \leftarrow j + 1$ 
6:   if  $j = m$  then
7:     Write( $i$ )
8:    $i \leftarrow i + 1$ 
```

Uwaga! Do alfabetu Σ dodajemy dwa *nowe*, specjalne symbole, powiedzmy \$ i @. Przed uruchomieniem algorytmu \$ dopisujemy na końcu t , natomiast @ na końcu p . Pełnią one rolę „strażników” w wewnętrznej pętli **while**.


Złożoność czasowa: $O((n - m + 1)m) = O(nm)$.

Poprawianie alg. „naiwnego”

Założmy, że dla $j + 1$ dostaliśmy niezgodność.

Wiemy, że $p[1..j]$ pasuje do $t[i..i + j - 1]$. Ile symboli możemy „przeskoczyć”?

Co się dzieje, gdy wzorec występuje na jednej z pozycji $i + 1, \dots, i + j - 1$?



Prefiks $p[1..j]$ jest równocześnie jego (właściwym) sufiksem! tzn. $p[1..k] = p[j - k + 1..j]$.

Jeśli to jest pierwsze miejsce, w którym występuje taka sytuacja, możemy bezpiecznie przesunąć i do $i + j - k$. Wystarczy znać k .

Poprawianie alg. „naiwnego”, cd.

Dla $j > 0$ chcemy więc znać liczbę:

$\Pi[j]$ = długość największego właściwego sufiksu $p[1..j]$, który jest równocześnie prefiksem p , czyli

$$\Pi[j] = \max\{0 \leq k < j : p[1..k] \text{ jest sufiksem } p[1..j]\}$$

Wtedy możemy bezpiecznie dopasowywać wzorzec w miejscu $i + j - \Pi[j]$.

Dla $j = 0$ przyjmijmy $\Pi[j] = 0$. Ojej! Ale wtedy $i + j - \Pi[j] = i$ i stoimy w miejscu. A więc ostatecznie przesuwamy i na pozycję $i + \max(1, j - \Pi[j])$.

Zauważmy też, że nie musimy już sprawdzać pierwszych $\Pi[j]$ liter wzorca!

Przykład. Tablica Π dla wzorca $p = abacabacaa$.

i	1	2	3	4	5	6	7	8	9	10
$p[i]$	a	b	a	c	a	b	a	c	a	a
$\Pi[i]$	0	0	1	0	1	2	3	4	5	1

Algorytm KMP

```
1:  $i \leftarrow 1$ 
2:  $j \leftarrow 0$ 
3: while  $i \leq n - m + 1$  do
4:    $\{p[1..\Pi[j]] = p[j - \Pi[j] + 1..j] =$   

    $t[i..i + \Pi[j] - 1]\}$ 
5:    $j \leftarrow \Pi[j]$ 
6:   while  $p[j + 1] = t[i + j]$  do
7:      $j \leftarrow j + 1$ 
8:   if  $j = m$  then
9:     Write( $i$ )
10:   $i \leftarrow i + \max(1, j - \Pi[j])$ 
```

Powyższy algorytm wymyślili panowie Knuth i Pratt oraz (niezależnie) Moris w 1977 roku.

Własności tablicy Π

$\Pi[j]$ = długość największego właściwego sufiksu $p[1..j]$, który jest równocześnie prefiksem p .

A gdybyśmy chcieli znać długości *wszystkich* właściwych sufiksów $p[1..j]$, które są prefiksami p ?

Niech $p = abababab$.


$p[1..8]$	$ab ab\ ab\ ab$	$\Pi[8] = 6$
$p[1..6]$	$ab ab\ ab$	$\Pi[6] = 4$
$p[1..4]$	$ab ab$	$\Pi[4] = 2$
$p[1..2]$	$ab $	$\Pi[2] = 0$
$p[0..0]$	ϵ	$\Pi[0] = 0$

Wniosek. Z tablicy Π można odczytać długości *wszystkich* właściwych sufiksów $p[1..j]$, które są równocześnie prefiksami p : są to liczby

$$\Pi[j], \Pi[\Pi[j]], \Pi^3[j], \dots$$

Jak obliczyć tablicę Π ?

Skorzystamy z programowania dynamicznego.



Jeśli $p[1..k]$ jest właściwym sufiksem i równocześnie prefiksem $p[1..j]$ to:

- $p[1..k - 1]$ jest właściwym sufiksem i prefiksem $p[1..j - 1]$,
- $p[k] = p[j]$.

Czyli żeby obliczyć $\Pi[j]$ trzeba znaleźć najdłuższy sufiks $p[1..j - 1]$, będący równocześnie prefiksem $p[1..j - 1]$, który *da się przedłużyć*, czyli *najmniejsze* s takie że:

$$p[\Pi^s[j - 1] + 1] = p[j].$$

Jeśli nie ma takiego s (tzn. żadnego, nawet pustego prefiksu nie da się przedłużyć), to

$$\Pi[j] = 0.$$

Obliczanie tablicy Π

```
1:  $\Pi[0] \leftarrow 0$ 
2:  $\Pi[1] \leftarrow 0$ 
3: for  $j \leftarrow 2$  to  $m$  do
4:   {obliczamy  $\Pi[j]$ }
5:    $x \leftarrow \Pi[j - 1]$ 
6:   while  $(x > 0)$  and  $(p[x + 1] \neq p[j])$  do
7:      $x \leftarrow \Pi[x]$  {próbujemy ktośszy sufiks}
8:   if  $p[x + 1] = p[j]$  then
9:      $\Pi[j] \leftarrow x + 1$ 
10:  else
11:     $\Pi[j] \leftarrow 0$ 
```

Złożoność czasowa: $\Theta(m)$

Złożoność czasowa KMP: $\Theta(n + m)$ **Złożoność**
pamięciowa KMP: $\Theta(m)$