

# Algorytm Manachera

Oznaczmy:

|       |  |
|-------|--|
| $w$   | niepusty łańcuch znaków.                                   |
| $p_P$ | palindrom parzysty postaci $p_P = ww^R$                    |
| $p_N$ | palindrom nieparzysty postaci $p_N = wXw^R$                |
| $r_p$ | promień palindromu - długość podłowa $w$                   |
| $i_s$ | Środek palindromu – pozycja pierwszego znaku za słowem $w$ |

Algorytm Manachera wyznacza maksymalne palindromy, których środki występują na kolejnych pozycjach znakowych przeszukiwanego łańcucha  $s$ . Dzięki takiemu podejściu redukujemy złożoność obliczeniową fazy przeszukiwania łańcucha  $s$ . Mając maksymalny palindrom możemy bez problemów wyznaczyć zawarte w nim podpalindromy. Wykorzystujemy tutaj własność symetrii palindromu:

Dla danego łańcucha  $s$  algorytm Manachera tworzy tablicę dwuwymiarową  $R$ :


$R[0, \dots]$  – promienie palindromów parzystych

$R[1, \dots]$  – promienie palindromów nieparzystych

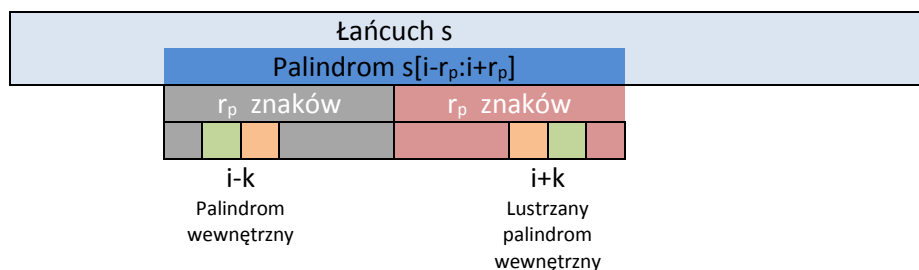
Indeksy tych tablic określają kolejne pozycje znakowe w łańcuchu  $s$ , natomiast wartości zawierają maksymalne promienie palindromów o środkach na danej pozycji.

Używając w odpowiedni sposób tablicy  $R$  oraz własności symetrii palindromu, algorytm Manachera wykorzystuje sprytnie informację o wcześniej wyznaczonych promieniach palindromów maksymalnych do wyszukiwania następnych palindromów. Otóż po wyznaczeniu promienia  $r_p$  palindromu na pozycji  $i$ -tej w łańcuchu  $s$ , sprawdzane są promienie palindromów na kolejnych pozycjach poprzedzających pozycję  $i$ -tą w obszarze podłowa  $w$  – tutaj algorytm wymaga dwóch wersji – osobnej dla palindromów parzystych i osobnej dla nieparzystych. Zasada jest identyczna dla obu wersji. Rozważmy zatem możliwe przypadki ( dla palindromu parzystego ):

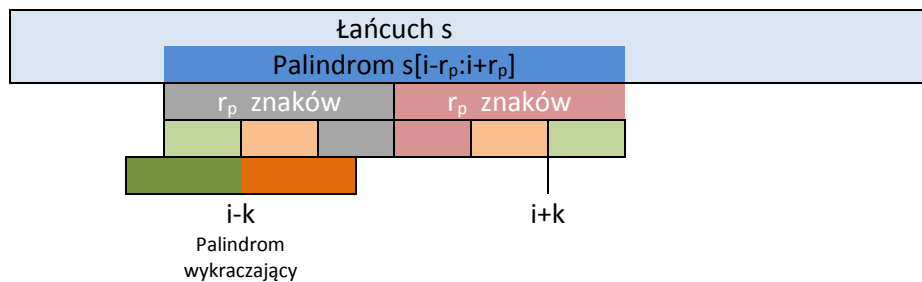
- a) Pozycja  $i-k$ , dla  $k=1,2,\dots,r_p$  **nie jest środkiem** żadnego palindromu, skoro tak, to przez symetrię możemy stwierdzić, że na pozycji lustrzanej  $i+k$  również nie będzie żadnego palindromu. Pozycja  $i+k$  może zostać pominięta przy dalszym wyszukiwaniu palindromów.




- b) Na pozycji  $i - k$  jest palindrom o promieniu  $r < r_p - k$  (w całości zawiera się wewnątrz rozważanego palindromu i nie styka się z jego brzegiem). Poprzez symetrię wnioskujemy, iż na pozycji  $i + k$  również musi występować taki sam palindrom, którego już dalej nie da się rozszerzyć. Pozycji  $i + k$  nie musimy już dalej sprawdzać.



- c) Na pozycji  $i - k$  jest palindrom o promieniu  $r > r_p - k$  (wykracza z lewej strony poza obszar rozważanego palindromu). Na pozycji  $i + k$  znajduje się palindrom o promieniu  $r = r_p - k$  i palindromu tego nie da się już rozszerzyć. Wyjaśnienie tego faktu jest bardzo proste – gdyby palindrom na pozycji  $i + k$  posiadał większy promień niż wyliczone  $r$ , to również z uwagi na symetrię przeglądany palindrom posiadałby promień większy od  $r_p$ , a przecież jest to palindrom maksymalny. Pozycję  $i+k$  również możemy pominąć.



- d) na pozycji  $i - k$  występuje palindrom o promieniu  $r = r_p - k$ . Taki sam palindrom musi być na pozycji  $i + k$ , jednakże w tym przypadku palindrom ten może być rozszerzalny. Pozycję  $i + k$  musimy zatem sprawdzić na obecność palindromu o promieniu większym od  $r$ .





## Sposób działania algorytmu:

**Tablica P** - przechowuje długości maksymalnych prefikso-sufiksów dla kolejnych prefiksów łańcucha s. Indeks w tablicy P oznacza długość prefiksu łańcucha s, natomiast element o tym indeksie ma wartość długości maksymalnego prefikso-sufiksu w danym prefiksie. Na przykład, jeśli  $P[6] = 2$ , to prefiks 6-cio znakowy łańcucha s posiada prefikso-sufiks maksymalny o długości dwóch znaków.

1. Początkowo w zerowym elemencie tablicy umieszczamy wartownika (minus jeden)

A B A A B A C A B A A B A B

Tablica  
P -1

2. Prefiks jednoznakowy A posiada prefikso-sufiks pusty, ponieważ prefikso-sufiks musi się składać z prefiksu i sufiksu właściwego.

A B A A B A C A B A A B A B

Tablica  
P -1 0

3. Prefiks dwuznakowy AB posiada prefikso-sufiks pusty

A B A A B A C A B A A B A B

Tablica  
P -1 0 0

4. Prefiks trzyznakowy ABA posiada prefikso-sufiks o długości jeden

A B A A B A C A B A A B A B

Tablica  
P -1 0 0 1

5. Sprawdzamy czy da się rozszerzyć poprzedni prefikso-sufiks o jeszcze jeden znak (porównując żółte znaki)

A B A A B A C A B A A B A B

Tablica  
P -1 0 0 1 1

Postępujemy w dalszym ciągu tak samo, a gdy napotkamy na brak możliwości rozszerzenia prefikso-sufiksu, próbujemy sprawdzić czy da się rozszerzyć zredukowany prefikso-sufiks (poprzedniego sufiksu)

Widać to na końcowym etapie działania tego algorytmu:

A B A A B A C A B A A B A B

|           |    |   |   |   |   |   |   |   |   |   |   |   |   |   |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|
| Tablica P | -1 | 0 | 0 | 1 | 1 | 2 | 3 | 0 | 1 | 2 | 3 | 4 | 5 | 6 |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|

Prefikso-sufiksu ABAABA nie da się rozszerzyć o jeden znak, należy więc sprawdzić czy prefikso-sufiks tego prefiksu (to jest ABA) jest rozszerzalny

A B A A B A C A B A A B A B

|           |    |   |   |   |   |   |   |   |   |   |   |   |   |   |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|
| Tablica P | -1 | 0 | 0 | 1 | 1 | 2 | 3 | 0 | 1 | 2 | 3 | 4 | 5 | 6 |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|

^

Długość prefiksu wynosi 6 (jest ona zapisana w tablicy P).

A B A A B A C A B A A B A B

|           |    |   |   |   |   |   |   |   |   |   |   |   |   |   |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|
| Tablica P | -1 | 0 | 0 | 1 | 1 | 2 | 3 | 0 | 1 | 2 | 3 | 4 | 5 | 6 |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|

^

Interesuje nas więc szósty element tablicy P. P[6] wynosi 3. Oznacza to długość maksymalnego prefikso-sufiksu o długości 6 (tym prefikso-sufiksem jest ABA). Lecz ABA także nie jest rozszerzalna (patrz żółte litery). Sprawdzamy więc czy rozszerzalny jest prefikso-sufiks tego trzyznakowego prefiksu (jego długość wynosi jeden – jest zapisana w tablicy w P[3])

A B A A B A C A B A A B A B

|           |    |   |   |   |   |   |   |   |   |   |   |   |   |   |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|
| Tablica P | -1 | 0 | 0 | 1 | 1 | 2 | 3 | 0 | 1 | 2 | 3 | 4 | 5 | 6 |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|

Ten prefiks jest rozszerzalny. P[14] wyniesie więc dwa.

A B A A B A C A B A A B A B

|           |    |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| Tablica P | -1 | 0 | 0 | 1 | 1 | 2 | 3 | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 2 |
|-----------|----|---|---|---|---|---|---|---|---|---|---|---|---|---|---|


Kod programu:

---


```
int pi[1000000];
string a;
int main()
{
    pi[0] = -1;
    cin>>a;
    a = "#"+a;
    int dl=a.size();
    for(int i=1;i<=dl;i++)
    {
        int x = pi[i-1];
        while(x!=-1)
        {
            if(a[x+1] == a[i])
            {
                pi[i] = x+1;
                break;
            }
            x = pi[x];
        }
    }
    for(int i=0;i<dl;i++)
        cout<<pi[i]<<" ";
    return 0;
}
```

Jak wykorzystamy ten algorytm do poszukiwania wzorca w tekście?

Załóżmy, iż poszukujemy pierwszego wystąpienia wzorca  $p$  w danym łańcuchu tekstowym  $s$ . W trakcie porównywania kolejnych znaków łańcucha ze znakami wzorca natrafiliśmy na sytuację, w której pewien prefiks wzorca  $p$ , pasuje do prefiksu okna w łańcuchu  $s$ , jednakże znak  $s$  oznaczony na rysunku symbolem X różni się od znaku oznaczonego symbolem Y, który znajduje się we wzorcu tuż za pasującym prefiksem:



Algorytm naiwny w takiej sytuacji przesuwa okno wzorca o jedną pozycję w prawo względem przeszukiwanego tekstu i rozpoczyna od początku porównywanie znaków wzorca  $p$  ze znakami okna nie korzystając zupełnie z faktu zgodności części znaków. Tymczasem wykorzystując fakt, że w naszym pasującym prefiksie istnieje jakiś najdłuższy prefikso-sufiks, możemy pominąć pewne porównania znaków bez żadnej szkody dla wyniku poszukiwań. Następne miejsce gdzie możemy podłożyć okno wzorca zaczyna się w naszym tekście tam, gdzie zaczyna się ten maksymalny prefikso-sufiks:



Dla każdego prefiksu wzorca szerokość maksymalnego prefikso-sufiksu można wyznaczyć przed rozpoczęciem wyszukiwania – do tego właśnie celu wykorzystamy algorytm *omówiony wcześniej*. Dla danej długości prefiksu  $b$  możemy odczytać szerokość maksymalnego prefikso-sufiksu tego prefiksu. W naszym przypadku będzie to:

$$bb = \Pi [ b ]$$

Teraz porównujemy znak wzorca  $p [ bb ]$  ( oznaczony na rysunku symbolem C ) ze znakiem  $s [ i ]$  ( symbol A ). Jeśli wciąż mamy niezgodność, to procedurę powtarzamy, aż do wyczerpania się prefikso-sufiksów – w takim przypadku okno wzorca oraz indeks  $i$  przesuwamy o jedną pozycję w prawo.

Jeśli otrzymamy zgodność, to pasujący prefiks zwiększa swoją długość o 1 znak. Przesuwamy również indeks  $i$  o 1, ponieważ znak na tej pozycji został już całkowicie wykorzystany przez algorytm MP.

```

// dla wzorca obliczamy tablicę PI [ ]

PI [ 0 ] = b = -1;
for( i = 1; i <= M; i++ )
{
    while( ( b > -1 ) && ( p [ b ] != p [ i - 1 ] ) ) b = PI [ b ];
    PI [ i ] = ++b;
}

// wypisujemy wzorzec

cout << p << endl;

// wypisujemy łańcuch s

cout << s;

// poszukujemy pozycji wzorca w łańcuchu

pp = b = 0;
for( i = 0; i < N; i++ )
{
    while( ( b > -1 ) && ( p [ b ] != s [ i ] ) ) b = PI [ b ];
    if( ++b == M )
    {
        while( pp < i - b + 1 )
        {
            cout << " "; pp++;
        }
        cout << "^"; pp++;
        b = PI [ b ];
    }
}
cout << endl;

```