

Najdłuższy Wspólny Podciąg (Longest Common Subsequence)

Jest to przykład algorytmu ilustrującego metodę *programowania dynamicznego*.

Dane: ciągi $X = x_1, x_2, \dots, x_m$ oraz $Y = y_1, y_2, \dots, y_n$.

Wynik: ciąg $Z = z_1, z_2, \dots, z_k$ który jest podciągiem zarówno ciągu X jak i Y i to najdłuższym podciągiem o tej własności (znajdujemy tylko jeden podciąg).

Przykład:

$X = \text{aabbcc}$

$Y = \text{abacb}$

Najdłuższy wspólny podciąg X i Y : **aab**

ale też: **abb abc aab**

Najprostsza strategia szukania NWP: wygenerować wszystkie podciągi X i zaczynając od najdłuższych sprawdzać, który jest również podciągiem Y . Złożoność pesymistyczna wykładnicza bo podciągów X jest 2^m .

Przeanalizujmy problem

Niech $X = x_1, x_2, \dots, x_m$. Wtedy X_i oznacza ciąg x_1, x_2, \dots, x_i , czyli początkowy fragment ciągu X do pozycji i włącznie.

(X_0 oznacza ciąg pusty a $X_n = X$)

Skrót NWP oznacza: “najdłuższy wspólny podciąg”

Stwierdzenie Niech $X = x_1, x_2, \dots, x_m$, $Y = y_1, y_2, \dots, y_n$ i niech $Z = z_1, z_2, \dots, z_k$ będzie dowolnym NWP X i Y . Wtedy

1. jeżeli $x_m = y_n$ to $z_k = x_m = y_n$ i Z_{k-1} jest NWP X_{m-1} i Y_{n-1} .
2. jeżeli $x_m \neq y_n$ i $z_k \neq x_m$ to Z jest NWP X_{m-1} i Y .
3. jeżeli $x_m \neq y_n$ i $z_k \neq y_n$ to Z jest NWP X i Y_{n-1} .

Dowód

$$X = X_m = x_1, x_2, \dots, x_{m-1}, x_m$$


$$Y = Y_n = y_1, y_2, \dots, y_{n-1}, y_n$$

$$Z = Z_k = z_1, z_2, \dots, z_{k-1}, z_k$$

To uzasadnia następujący algorytm

```
LCSr( $X_m, Y_n$ )  
  if  $m==0$  or  $n==0$   
    return pusty ciąg  
  if  $x_m == y_n$   
    return LCSr( $X_{m-1}, Y_{n-1}$ ) +  $x_m$   
  else  
     $Z_1 = \text{LCSr}(X_{m-1}, Y_n)$   
     $Z_2 = \text{LCSr}(X_m, Y_{n-1})$   
    return dłuższy spośród  $Z_1, Z_2$ 
```

Złożoność pesymistyczna LCSr jest niestety wykładnicza.



Drzewo rekursji do poziomu $\min(m, n)$ jest pełnym drzewem binarnym, jeżeli ciągi X i Y nie mają wspólnych znaków. Wywołań rekurencyjnych jest $\Theta(2^{\min(m, n)})$. Dzieje się tak, bo wielokrotnie powtarzamy te same obliczenia.

Idea efektywnego rozwiązania. Organizujemy obliczenie tak, żeby tylko raz liczyć powtarzające się obliczenia i spamiętywać ich wyniki do ponownego wykorzystania. Takie organizowanie obliczenia nazywamy właśnie *programowaniem dynamicznym*.

Dla $i = 0, 1, \dots, m$ oraz $j = 0, 1, \dots, n$ wyliczymy długość $NWP(X_i, Y_j)$ i zapamiętujemy tę wartość w tablicy (dwuwymiarowej) $c[i, j]$.

Ażeby wyliczyć $c[i, j]$ wystarczy wiedzieć jakie są x_i i y_j oraz znać wartości $c[i-1, j-1]$, $c[i-1, j]$, $c[i, j-1]$.

$i \setminus j$	(0)	y_1 (1)	y_2 (2)	y_j (i)	\dots	y_n (n)
	0	0	0	0	0	0
x_1 (1)	0					
x_2 (2)	0					
x_i (i)	0					
\dots	0					
x_m (m)	0					

The diagram illustrates a sequence of red dotted arrows starting from the first row of zeros and pointing to the first column of zeros, illustrating a path through the matrix. The arrows start from the first row of zeros and point to the first column of zeros, illustrating a path through the matrix. The arrows start from the first row of zeros and point to the first column of zeros, illustrating a path through the matrix.

Najdłuższy Wspólny Podciąg (wersja iteracyjna)

Ciagi wejściowe indeksowane od pozycji 1, czyli

$x[1], x[2], \dots, x[m]$

$y[1], y[2], \dots, y[n]$.

Tablice c, b indeksowane od 0.

w $c[i,j]$ wyliczymy długość $NWP(X_i, Y_j)$

LCS-Length(x,y)

$m = x.length$

$n = y.length$

 for $i = 0$ to m

$c[i,0] = 0$

 for $j = 1$ to n

$c[0,j] = 0$

 for $i = 1$ to m

 for $j = 1$ to n

 if $x[i]==y[j]$

$c[i,j] = c[i-1,j-1]+1$

$b[i,j] = "\backslash"$

 else if $c[i-1,j] \geq c[i,j-1]$

$c[i,j] = c[i-1,j]$

$b[i,j] = "|"$

 else

$c[i,j] = c[i,j-1]$

$b[i,j] = "-"$

 return b, c

Drukowanie wyniku

```
PrintLCS(x,b,i,j)
  if i==0 lub j==0
    return
  if b[i,j] == "\"
    PrintLCS(x,b,i-1,j-1)
    drukuj x[i]
  else if b[i,j] == "|"
    PrintLCS(x,b,i-1,j)
  else
    PrintLCS(x,b,i,j-1)
```


Stwierdzenie Złożoność pesymistyczna znalezienia i wypisania najdłuższego wspólnego podciagu ciągów o długościach m i n , przy zastosowaniu metody programowania dynamicznego jest $\Theta(mn)$.

Uwaga Można nie używać pomocniczej tablicy \mathbf{b} a wyliczać na bieżąco jej zawartości na podstawie \mathbf{x} i \mathbf{y}

Wersja rekurencyjna ze spamiętywaniem

```
LCS-Rec(x,y)
  m = x.length
  n = y.length
  for i = 1 to m
    for j = 1 to n
      c[i,j]= INFINITY
  for i = 1 to m
    c[i,0] = 0
  for j = 0 to n
    c[0,j] = 0
  LCS-Lookup(m,n,c,b)
  return b,c
```

```
LCS-Lookup(i,j,c,b)
  if c[i,j]<INFINITY
    return c[i,j]
  if x[i]=y[j]
    c[i,j] = LCS-Lookup(i-1,j-1,c,b)+1
    b[i,j] = "\"
  else c1 = LCS-Lookup(i-1,j,c,b)
       c2 = LCS-Lookup(i,j-1,c,b)
       if c1>=c2 // czyli c[i-1,j] >= c[i,j-1]
         c[i,j] = c1
         b[i,j] = "|"
       else
         c[i,j] = c2
         b[i,j] = "-"
  return c[i,j]
```