

Développement : plus longue sous-séquence commune

PIERRON Théo

10 avril 2014

Définition On dit que Z est une sous-séquence de X ssi on peut obtenir Z en effaçant des lettres de X , ie il existe des indices $(i_j)_j$ strictement croissants tels que $z_j = x_{i_j}$.

Étant données deux chaînes de caractères X et Y , on cherche une plus longue sous-séquence qui est commune à X et Y . (on note X_i le i -ème préfixe de X , de même pour Y et Z).

THÉORÈME STRUCTURE DES SOLUTIONS OPTIMALES Si $X = x_1 \dots x_m$, $Y = y_1 \dots y_n$ et $Z = z_1 \dots z_k$ est une PLSC de X et Y alors :

- Si $x_m = y_n$ alors $z_k = x_m$ et Z_{k-1} est une PLSC de X_{m-1} et Y_{n-1}
- Si $x_m \neq y_n$ et $z_k \neq x_m$ alors Z est une PLSC de X_{m-1} et Y
- Si $x_m \neq y_n$ et $z_k \neq y_n$ alors Z est une PLSC de X et Y_{n-1}

Démonstration.

- Si $x_m = y_n$, supposons que $z_k \neq x_m$. Alors Zx_m est une sous-séquence de X et Y strictement plus longue que Z , ce qui est absurde. Donc $z_k = x_m$.
Si Z_{k-1} n'est pas une PLSC de X_{m-1} et Y_{n-1} , soit W une telle PLSC. Wz_k est une sous-séquence de X et Y et

$$|Wz_k| = 1 + |W| > 1 + |Z_{k-1}| = |Z_k|$$

Absurde. Donc Z_{k-1} est une PLSC de X_{m-1} et Y_{n-1} .

- Si $x_m \neq y_n$ et $z_k \neq x_m$, Z est une sous-séquence de X_{m-1} et Y . Supposons que ce n'est pas une PLSC, ie il existe W sous-séquence de X_{m-1} et Y telle que $|W| > |Z|$.
 W est aussi une sous-séquence de X et Y , strictement plus grande que Z , ce qui est absurde. Donc Z est une PLSC de X_{m-1} et Y .
- Si $x_m \neq y_n$ et $z_k \neq y_n$, on est dans le cas symétrique. ■

On note $c[i, j]$ la longueur d'une PLSC de X_i et Y_j . On a alors la formule de récurrence :

$$c[i, j] = \begin{cases} 0 & \text{si } ij = 0 \\ 1 + c[i-1, j-1] & \text{si } ij > 0 \text{ et } x_i = y_j \\ \max(c[i-1, j], c[i, j-1]) & \text{sinon} \end{cases}$$

Cette relation conduit naturellement à l'algorithme 1, qui utilise la programmation dynamique.

La complexité est en $O(mn)$ en espace et en temps.

On peut alors reconstruire une PLSC à partir de b , via l'algorithme 2, de complexité $O(m+n)$ au pire.

Algorithme 1: CoûtPLSC(X, Y)

Entrées : Deux mots X et Y

Sorties : Le tableau c , et un tableau b permettant de reconstruire une PLSC de X et Y

```
1 pour  $i = 0 \dots m$  faire
2    $c[i, 0] \leftarrow 0$ 
3 pour  $j = 0 \dots n$  faire
4    $c[0, j] \leftarrow 0$ 
5 pour  $i = 1 \dots m$  faire
6   pour  $j = 1 \dots n$  faire
7     si  $x_i = y_j$  alors
8        $c[i, j] \leftarrow 1 + c[i - 1, j - 1]$   $b[i, j] \leftarrow \swarrow$ 
9     sinon
10      si  $c[i - 1, j] > c[i, j - 1]$  alors
11         $c[i, j] \leftarrow c[i - 1, j]$   $b[i, j] \leftarrow \uparrow$ 
12      sinon
13         $c[i, j] \leftarrow c[i, j - 1]$   $b[i, j] \leftarrow \leftarrow$ 
14 retourner  $(c, b)$ 
```

Algorithme 2: PLSC(b, X, i, j)

Entrées : Le tableau b , la chaîne X et deux indices i, j

Sorties : L'affichage d'une PLSC associée à b

```
1 si  $ij = 0$  alors
2   retourner Fin
3 sinon
4   si  $b[i, j] = \swarrow$  alors
5     PLSC( $b, X, i - 1, j - 1$ ) Affiche  $x_i$ 
6   sinon
7     si  $b[i, j] = \uparrow$  alors
8       PLSC( $b, X, i - 1, j$ )
9     sinon
10      PLSC( $b, X, i, j - 1$ )
```
