

DISTANCE D'EDITION ET FACTEURS

Leçons 907, 921

Référence Crochemore

Navarro, Flexible pattern matching in strings.

Théorème

Soit Σ un alphabet

$s, t \in \Sigma^*$.

On définit la distance d'édition de s à t comme le nombre d'opérations élémentaires (insertion, suppression, substitution) pour transformer l'une en l'autre.

On peut calculer cette distance en $O(|s| \cdot |t|)$ par programmation dynamique.

De plus, l'algorithme peut facilement être adapté pour rechercher les occurrences à distance au plus k de s dans t en temps $O(k|t|)$.

Résumé

I - Relation de récurrence et sous-problème optimal.

II - Adaptation pour les facteurs.

III - Calcul de la complexité.

IV - Un alignement de s et t est une façon d'observer leur similarité, de la forme, par exemple :

(	A	C	G	-	-	A	)
(	A	T	-	C	T	A	)
		↑	↑		↑		
		substitution	suppression		insertion		

C'est un mot sur $(\Sigma \cup \{\epsilon\})^* \setminus \{(\epsilon, \epsilon)\}$.

Le coût est le nombre d'opérations.

La distance d'édition $d(s, t)$ est donc

$$d(s, t) = \min_{\text{alignements}} \text{cout}$$

On a alors le sous-problème optimal suivant:

si α est un alignement optimal de longueur n ,
 $\alpha[1, \dots, n-1]$ est un alignement optimal.

Cela permet de définir la relation de récurrence:

$$\begin{cases} d(\varepsilon, \varepsilon) = 0 \\ d(x, \varepsilon) = |x| \\ d(\varepsilon, y) = |y| \\ d(x, y) = \min \begin{cases} d(x[1, \dots, |x|-1], y) + 1 \\ d(x, y[1, \dots, |y|-1]) + 1 \\ d(x[1, \dots, |x|-1], y[1, \dots, |y|-1]) + \delta_{x[|x|], y[|y|]} \end{cases} \end{cases}$$

On peut le traduire en algorithme:

DISTANCE(s, t):

$D = \begin{bmatrix} 0 \end{bmatrix}$

Pour $i = 0$ à $|s|$: $D[i][0] = i$

Pour $j = 0$ à $|t|$: $D[0][j] = j$

Pour $i = 1$ à $|s|$:

 Pour $j = 1$ à $|t|$:

$\delta = 0$

 Si $s[i] \neq t[j]$: $\delta = 1$

$D[i][j] = \min(D[i-1][j] + 1, D[i][j-1] + 1, D[i-1][j-1] + \delta)$

Retourner $D[|s|][|t|]$.

$\Rightarrow$ Complexité $O(|s| \cdot |t|)$.

Exemple

	ϵ	b	a	a	c	b
ϵ	(0) ₀	(1) ₀	(2) ₀	(3) ₀	(4) ₀	(5) ₀
a	1 ₁	1 ₁	(1) ₀	2 ₀	3 ₁	4 ₁
b	2 ₂	1 ₁	2 ₁	(2) ₁	3 ₂	3 ₁
c	3 ₃	2 ₂	2 ₂	3 ₂	(2) ₁	3 ₂
a	4 ₄	3 ₃	2 ₂	2 ₂	(3) ₂	4 ₂
b	5 ₅	4 ₄	3 ₃	3 ₃	3 ₃	(3) ₂

→ $\begin{pmatrix} b & a & a & c & - & b \\ - & a & b & c & a & b \end{pmatrix}$

on obtient un alignement en se rappelant des choix qu'on a faits.

II) On peut adapter l'algo pour rechercher des facteurs d'édition à distance d'édition $\leq k$ par exemple.

Pour cela on remarque que le mot vide est facteur à distance d'édition nulle de tout mot.

→ on change donc juste $d(\epsilon, y) = 0$.

On trouve donc tous les facteurs en $O(|s| \cdot |t|)$


~~III) En fait on peut faire mieux. Pour cela on définit les cellules actives: une cellule du tableau est active si elle a une valeur $\leq k$.~~

~~La position de la cellule active la plus basse ne peut alors être incrémentée que de 1 à chaque lettre du texte, dans le cas où on lit deux fois la même lettre.~~

III) On a besoin de définir deux types de nœuds: sur chaque diagonale orientée ↘ :

* un d -nœud : la dernière paire (i, j) telle que $D[i][j] = d$ sur une diagonale

* un d -nœud spécial: un nœud que l'on peut atteindre en un coup depuis un $(d-1)$ -nœud.



On doit ensuite descendre sur les diagonales selon le plus long chemin de poids 0 pour trouver les d -nœuds.

→ c'est-à-dire, pour un d -nœud spécial (i, j) , on cherche le plus long préfixe de $s[1..i]$ commun à $t[1..j]$.

Comme il y a $|t|$ diagonales, on peut passer des $(d-1)$ -nœuds aux d -nœuds en $O(|t|)$. Ensuite, on peut descendre le long d'une diagonale en $O(1)$ car cela revient à chercher le dernier caractère commun de deux suffixes dans l'arbre des suffixes communs à s et t (*)

De plus le cas $d=0$ correspond à une recherche sans erreur, qui se fait en temps linéaire.

(*) La construction linéaire de l'arbre se fait avec l'algorithme d'Ukkonen, mais c'est pas évident, et après il faut calculer les ancêtres communs en temps linéaire, ce qui en rajoute une couche.