

CALCUL D'UN ALIGNEMENT LOCAL

Lachemore p257

Considérons et des fonctions de Σ dans Σ^* finies.
 Considérons aussi une fonction de Σ^2 dans \mathbb{Z}^* ≥ 0 sur la diagonale
 < 0 en dehors.

Soient $x = x_1 \dots x_n$ et $y = y_1 \dots y_m$ deux mots sur Σ .

On introduit $s_{i,j} = \max \{ \text{Sim}(x_k - x_i, y_k - y_j) \mid k \in [1..n], k \in [i..j+1] \}$
 = le score d'un alignement local de $x_i \dots x_j$, $y_i \dots y_j$ finissant en i, j et maximal.

NB: On considère des suffixes plutôt que des facteurs quelconques en vue de prolonger ces alignements locaux.
 Si le score retenu était réalisé par un alignement d'un facteur finissant quelques caractères auparavant, cela n'aurait pas de sens de chercher à le prolonger d'une ins, sub ou del ...

Pt'

- $\forall i \in [0..n] \quad s_{i,0} = 0$
- $\forall j \in [0..m] \quad s_{0,j} = 0$

- $\boxed{\forall (i,j) \in [1..n] \times [1..m] \quad s_{i,j} = \max \begin{cases} 0 \\ \text{sim}_{i,j} + \underline{\text{del}}(x_i) \\ s_{i,j-1} + \underline{\text{ins}}(y_j) \\ s_{i-1,j-1} + \underline{\text{sub}}(x_i, y_j) \end{cases}}$

Preuve

a). Puisque $y_1 \dots y_0 = \epsilon$, on cherche en fait ici à aligner un suffixe de x avec le mot vide.
 Pour tout facteur non vide on aura un coût de suppression, donc un score < 0 .

Il vaut mieux ne rien aligner, ce qui fait un score nul.

D'où $s_{i,0} = 0$.

Idem pour $s_{0,j} = 0$.

b) Notons $M_0 = 0$, $M_1 = s_{i-1,j} + \underline{\text{del}}(x_i)$, $M_2 = s_{i,j-1} + \underline{\text{ins}}(y_j)$, $M_3 = s_{i-1,j-1} + \underline{\text{sub}}(x_i, y_j)$,
 et $M = \max(M_0, M_1, M_2, M_3)$.

Montrons d'abord que $s_{i,j} \geq M$

- Puisque l'option de ne rien aligner est toujours possible, $s_{i,j} \geq 0 = M_0$ n'assure pas.

- Considérons (\tilde{u}, \tilde{v}) un alignement justifiant $s_{i-1, j}$, c.-à-d que $S(\tilde{u}, \tilde{v})$ est un alignement de $(x_k - x_i, y_k - y_j)$ pour certains k et ℓ , et que $S(\tilde{u}, \tilde{v}) = s_{i-1, j}$. Alors $(\tilde{u}x_i, \tilde{v}_-)$ est un alignement de $(x_k - x_i, y_k - y_j)$ donc $s_{i, j} \geq S(\tilde{u}x_i, \tilde{v}_-) = S(\tilde{u}, \tilde{v}) + \underline{\text{del}}(x_i) = s_{i-1, j} + \underline{\text{del}}(x_i)$. D'où $s_{i, j} \geq M_1$.
 - De m^e en considérant (\tilde{u}, \tilde{v}) justifiant $s_{i, j-1}$, $(\tilde{u}_-, \tilde{v}y_j)$ est un alignement de $(x_k - x_i, y_k - y_j)$ pour certains k et j donc $s_{i, j} \geq S(\tilde{u}_-, \tilde{v}y_j) = S(\tilde{u}, \tilde{v}) + \underline{\text{ins}}(y_j)$. D'où $s_{i, j} \geq M_2$.
 - Encore de m^e on a $s_{i, j} \geq s_{i-1, j-1} + \underline{\text{sub}}(x_i, y_j)$ soit $s_{i, j} \geq M_3$ en considérant (\tilde{u}, \tilde{v}) justifiant $s_{i-1, j-1}$.
- Donc $s_{i, j} \geq \max(M_0, M_1, M_2, M_3) = M$.

Réiproquement mentionnons que $s_{i, j} \leq M$ (ce qui montre finalem l'égalité des deux).

Considérons (\tilde{u}, \tilde{v}) un alignement de $(x_k - x_i, y_k - y_j)$ justifiant $s_{i, j}$, c.-à-d tel que $S(\tilde{u}, \tilde{v}) = s_{i, j}$. Notons $n = |\tilde{u}| = |\tilde{v}|$.

- Si $n=0$, alors $s_{i, j} = S(E, E) = 0$. Comme on a exhibé plus haut des alignement de suffisamment de $(x_k - x_i, y_k - y_j)$ de score M_1, M_2 ou M_3 , le fait que $s_{i, j}=0$ implique néc que $M_1 \leq 0, M_2 \leq 0$ et $M_3 \leq 0$. Donc $\max(M_0, M_1, M_2, M_3) = 0$ et alors on a bien $s_{i, j} = 0 = M$.
- Si $\tilde{u}_n = -$, alors néc $\tilde{v}_n = y_j$ donc $(\tilde{u}, \tilde{v}) := (\tilde{u}_- - \tilde{u}_n, \tilde{v}_- - \tilde{v}_{n-1})$ est un alignement de $(x_k - x_i, y_k - y_{j-1})$ donc $S(\tilde{u}, \tilde{v}) \leq s_{i, j-1}$. Or $S(\tilde{u}, \tilde{v}) = S(\tilde{u}, \tilde{v}) + \underline{\text{ins}}(y_j)$ donc $s_{i, j} \leq s_{i, j-1} + \underline{\text{ins}}(y_j) = M_2$ or $s_{i, j} \geq M_2$ donc $s_{i, j} = M_2$ et néc $M_2 \geq M_0$ $M_2 \geq M_1$ $M_2 \geq M_3$ ce qui dit $M_2 = M$.
dene $s_{i, j} = M$
- Si $\tilde{u}_n = -$ alors $\tilde{u}_k = x_i$ et $(\tilde{u}, \tilde{v}) := (\tilde{u}_- - \tilde{u}_n, \tilde{v}_- - \tilde{v}_{n-1})$ est un alignement de $(x_k - x_{i-1}, y_k - y_j)$ donc $s_{i, j} = S(\tilde{u}, \tilde{v}) = S(\tilde{u}, \tilde{v}) + \underline{\text{del}}(x_i) \leq s_{i-1, j} + \underline{\text{del}}(x_i) = M_1$ or $s_{i, j} \geq M_1$, donc $s_{i, j} = M_1$ et alors néc $M_1 = M$ d'où $s_{i, j} = M$
- Si non $\tilde{u}_n = x_i, \tilde{v}_n = y_j$ et $(\tilde{u}, \tilde{v}) := (\tilde{u}_- - \tilde{u}_n, \tilde{v}_- - \tilde{v}_{n-1})$ est un alignement de $(x_k - x_{i-1}, y_k - y_j)$ donc $s_{i, j} = S(\tilde{u}, \tilde{v}) = S(\tilde{u}, \tilde{v}) + \underline{\text{sub}}(x_i, y_j) \leq s_{i-1, j-1} + \underline{\text{sub}}(x_i, y_j) = M_3$ or $s_{i, j} \geq M_3$ donc $s_{i, j} = M_3$ et alors néc $M = M_3$, d'où $s_{i, j} = M$

Algo

LOC(x, y)

$n \leftarrow$ longueur (x)

$m \leftarrow$ longueur (y)

$T \leftarrow$ tableau indexé par $[0..n] \times [0..m]$
initialisé à 0

Pour j allant de 1 à m

Pour i allant de 1 à n

$T[i, j] \leftarrow \max \{ T[i-1, j-1] + \text{sub}(x_i, y_j), T[i-1, j] + \text{del}(x_i), T[i, j-1] + \text{ins}(y_j), 0 \}$

$\max \leftarrow 0$

Pour j allant de 1 à m

Pour i allant de 1 à n

Si $T[i, j] > \max$
alors $\max \leftarrow T[i, j]$

Retourner \max

Rq

* Si les cas de base sont compris dans la mix à 0 du tableau T puisque $s_{1,0} = s_{0,j} = 0$

A) Si -à ne pas renvoyer $T[n, m]$.

En effet le meilleur alignement local n'a aucun raison de se trouver à la fin de x terminer en x_n et y_m .

On a stocké dans $T[i, j]$ la valeur $s_{i,j}$ du meilleur alignement en terme de score, d'un suffrage de $x_i - x_i$ et d'un suffrage de $y_j - y_j$, parce que c'est ce dont on a besoin pour prolonger.

Il faut donc chercher le max en parcourant tous les points de pointrons de fin possible.

Complexité

La complexité temporelle est en $O(nm)$
spatiale

Algobis

Pour renvoyer l'alignem^t local et non plus xulém^t son score.

LOC_BIS (x_i, y_j)

$n \leftarrow$ longueur (x_i)

$m \leftarrow$ _____ (y_j).

$T \leftarrow$ tableau indexé par $[0..n] \times [0..m]$ initialisé à 0

$M \leftarrow$ _____

Pour j allant de 1 à m

Pour i allant de 1 à n

RAZ $\leftarrow 0$

INS $\leftarrow T[i, j-1] + \text{ins}(x_i, y_j)$

DEL $\leftarrow T[i-1, j] + \text{del}(x_i)$

SUB $\leftarrow T[i-1, j-1] + \text{sub}(x_i, y_j)$

Si $\max(\text{RAZ}, \text{INS}, \text{DEL}, \text{SUB}) = \text{RAZ}$

alors $T[i, j] \leftarrow 0$

$M[i, j] \leftarrow (-1, -1)$

Si _____ = INS

alors $T[i, j] \leftarrow \text{INS}$

$M[i, j] \leftarrow (i, j-1)$

Si _____ = DEL

alors $T[i, j] \leftarrow \text{DEL}$

$M[i, j] \leftarrow (i-1, j)$

Si _____ = SUB

alors $T[i, j] \leftarrow \text{SUB}$

$M[i, j] \leftarrow (i-1, j-1)$

$i_m \leftarrow 0; j_m \leftarrow 0$, res. \leftarrow mot vide

Pour j allant de 1 à m

Pour i _____

Si $T[i, j] > T[i_m, j_m]$

alors $i_m \leftarrow i; j_m \leftarrow j$

Pour i allant de 0 à n

$M[i, 0] \leftarrow (-1, -1)$

Pour j allant de 1 à m

$M[0, j] \leftarrow (-1, -1)$

| Cplx

complexité spatiale $O(mn)$
temporelle $O(m \times n)$

$\tilde{x} \leftarrow \epsilon; i \leftarrow i_m$
 $\tilde{y} \leftarrow \epsilon; j \leftarrow j_m$

Tant que $M[i, j] \neq (-1, -1)$
match $M[i, j]$ with

| $(i, j-1) \rightarrow \begin{cases} \tilde{x} \leftarrow -\tilde{x} \\ \tilde{y} \leftarrow y_j \end{cases}$

| $(i-1, j) \rightarrow \begin{cases} \tilde{x} \leftarrow x_i \tilde{x} \\ \tilde{y} \leftarrow -\tilde{y} \end{cases}$

| $(i-1, j-1) \rightarrow \begin{cases} \tilde{x} \leftarrow x_i \tilde{x} \\ \tilde{y} \leftarrow y_j \end{cases}$

$(i, j) \leftarrow M[i, j]$

retourner $(\tilde{x}, \tilde{y}, T[i_m, j_m])$

Rq

Pour favoriser le plus long alignement on veille à mettre le test du cas d'une remise à zéro (RAZ) en premier.

En effet si la possibilité d'un score nul est offerte par un alignement qui dérange d'un pas INS, DEL ou SUB c'est cette hypothèse qu'on retiendrait dans le tableau mémoire M , puisque dans l'un de ces cas on incrémente le valeur précédemment inscrite par le cas RAZ.

En fait les tests sont présentés peu à peu inverse de priorité, l'idée étant que le dernier est avantageé puisqu'il l'emporte.

Donc on privilie 1 la SUB, 2 la DEL, 3 INS, 4 RAZ.

ex

$$\underline{\text{del}} = -1 \quad \underline{\text{ins}} \begin{array}{l} (\text{voyelle}) = -1 \\ (\text{consonne}) = -2 \end{array}, \quad \underline{\text{sub}} \begin{array}{l} (\text{voyelle, voyelle}') = -1 \\ (\text{consonne, consonne}') = -1 \\ (\text{voyelle, consonne}) = -2 \\ (\text{voyelle, } \tilde{\text{m}} \text{ voyelle}) = 3 \\ (\text{consonne, } \tilde{\text{m}} \text{ consonne}) = 1 \end{array}$$

$x = \text{GRAVITER} \quad m = 8$

$y = \text{AGRANDIR} \quad m = 8$

	/	A	G	.	R	A	N	D	i	R
/	0	0	0	0	0	0	0	0	0	0
G	0	0	1	0	0	0	0	0	0	0
R	0	0	0	2 → 1	0	0	0	0	0	1
A	0	3 → 1	1	5 → 3 → 1 → 0	0	0	0	0	0	0
V	0	2	2	0	4	4	2 → 1	0	0	0
i	0	1	0	0	3	2	2	5 → 3	0	0
T	0	0	0	0	2	2	1	4	4	4
E	0	0	0	0	1	0	0	3	3	3
R	0	0	0	1	0	0	0	2	4	4

meilleur al. loc. $\begin{pmatrix} \text{GRA} & \text{VI} \\ \text{GRANDI} \end{pmatrix}$, de score 5.
 $1 \ 1 \ 3 \ -2 \ -1 \ 3$

autre meilleur al. local, de score aussi 5 $\begin{pmatrix} \text{GRA} \\ \text{GRA} \\ 1 \ 1 \ 3 \end{pmatrix}$