

Soit  $\Sigma$  un alphabet fini.

### I) Recherche d'un motif $P$ dans un Texte

Problème fréquent dans les traitements de texte, la bio-informatique, l'analyse musicale...  
On note  $P \in \Sigma^*$  le motif de longueur  $m$ , et  $T \in \Sigma^*$  le texte de longueur  $n$ .


#### 1) Algorithme naïf - Fenêtres glissantes [Cormen]

Pour  $k \in [1, n-m+1]$ :

$\left[ \begin{array}{l} S \\ T \end{array} \right]_{s=s+m-1} = P:$   
Afficher "occurrence de  $P$  en  $T$ "

} RECHERCHE\_NAIVE( $P, T$ )

Exemple : recherche de abab dans bababb



Prop 1 Dans le pire des cas, RECHERCHE\_NAIVE a une complexité temporelle en  $O(m(n-m+1))$  (comptée en nombre de comparaisons)

#### 2) Algorithme de Rabin-Karp [Cormen]

Les prochains algorithmes tentent d'améliorer la complexité par un prétraitement de  $P$  ou  $T$ . Celui de Rabin-Karp a une complexité au pire de  $O(m(n-m+1))$  aussi, mais il est très utile quand les textes sont courts, et dans la détection de plagiat.

Idee:  $\Sigma = \{0, 1, \dots, d\}$ . Soit  $q$  un entier fixe.

•  $W \in \Sigma^*$  est un mot en base  $d$ , noté en minuscule.

• Calcul par la méthode de Horner : par  $w_1 \dots w_k$ ,

$$\text{on calcule } w_k + d(w_{k-1} + d(\dots + dw_1)) [q].$$

• On note  $t_s$  le nombre associé à  $T[s+1 \dots s+m]$

$$t_{s+1} = d \cdot (t_s - T[s+1] h) + T[s+m+1] \bmod q$$

où  $h = d^{m-1}[q]$  est calculé à l'avance.

• Dans l'algorithme naïf, on effectue la comparaison

$$+ T[s \dots s+m-1] = P \text{ssi } p = t_{s+1}.$$

### 3) Algorithme de Knuth-Morris-Pratt [Cormen]

#### a) Automate des occurrences

Soit  $\sigma: \Sigma^* \rightarrow \{0, 1, \dots, m\}$  tq  $\sigma(x)$  est la longueur du plus long préfixe de  $P$  qui soit suffixe de  $x$ .

On définit un automate qui reconnaît  $\Sigma^*P$ :

Vérifier si  $P$  apparaît dans  $T$  est alors faisable en  $O(n)$ :

Les états sont  $\{0, 1, \dots, m\}$ , où 0 est initial et  $m$  final.

La fonction de transition  $S$  vérifie pour un état  $q$  et une lettre  $a$  :

$$S(q, a) = \sigma(P[1 \dots q] + a)$$

Exemple : Pour ababa



Thm 2  $A_p$  est l'automate minimal reconnaissant  $\Sigma^*P$ .

#### b) Fonction préfixe

On préfère utiliser une table  $\pi[1 \dots m]$  tq

$\pi[i]$  est le long préfixe de  $P$  qui est suffixe propre de  $P[1 \dots i]$ .

Prop 3 Dans  $A_p$ , si  $q=m$  ou que  $P[q+1] \neq a$ , on a

$$S(q, a) = S(\pi[q], a)$$

On peut donc recalculer  $A_p$  à partir de  $\pi$ .

FUNCTION\_PREFIXE( $P$ ): // Renvoie la table  $\pi$  associée à  $P$ .

```

 $\pi[1] \leftarrow 0$ 
 $R \leftarrow 0$ 
 $\text{Pour } q \in [2, m]:$ 
    Tant que  $R > 0$  et  $P[R+1] \neq P[q]$ :
         $L \leftarrow \pi[R]$ 
        Si  $P[R+1] = P[q]$  alors  $R \leftarrow R+1$ 
     $\pi[q] \leftarrow R$ 
    Renvoyer  $\pi$ 
  
```

Exemple : Pour ababca :

$$\pi = [0, 0, 1, 2, 0, 1]$$

Thm 4 FUNCTION\_PREFIXE renvoie  $\pi$  en  $O(m)$ .

### ② Algorithmes

Complexité temporelle en  $O(n+m)$

KMP( $T, P$ ):

$\pi \leftarrow \text{FONCTION\_PREFIXE}(P)$

$q \leftarrow 0$

for  $i \in [1, n]$ :

Tant que  $q > 0$  et  $P[q+1] \neq T[i]$ :  $q \leftarrow \pi[q]$

Si  $P[q+1] = T[i]$ :  $q \leftarrow q+1$

Si  $q = m$ :

Affiche "occurrence de  $P$  en  $i-m$ "

$q \leftarrow \pi[q]$


### ③ Arbre des suffixes

[Gochenore]

Déf 5 L'arbre des suffixes d'un mot  $T$ , noté  $A(Suff(T))$ , est

l'automate déterministe qui reconnaît  $Suff(T)$  l'ensemble des suffixes de  $T$ ,  
et dans lequel deux chemins de même origine ont toujours des fins distinctes.

Exemple  $\text{GS de } ababbb$




On insère les suffixes  $T[i..n]$  dans l'ordre croissant des  $i$ .

C'est avec cette convention que les sommets ont été numérotés.

Déf 6 L'arbre compact des suffixes de  $T$  s'obtient à partir de l'arbre des suffixes en supprimant les noeuds de degré 1 non terminaux.

Exemple  $\text{GS de } ababbb$



Pour vérifier que  $P$  a une occurrence dans  $T$ , il suffit de parcourir l'arbre compact:  
s'il existe un chemin étiqueté par  $P$ , c'est bon.

La recherche a donc une complexité  $O(m)$ , c'est le prétraitement qui prend une place immense !

Utilisé quand on a besoin de chercher de nombreux mots dans  $T$ .

Thm 7 (Wienz) On peut calculer l'arbre compact des suffixes de  $T$  avec une complexité au pire linéaire en l'espace et en temps.

### ④ Comparaisons de mots

Soit  $x \in \Sigma^m$  et  $y \in \Sigma^n$ .

1) Distance de Levenshtein [Gochenore] (chpt)

Le but est d'étudier la façon la plus rapide de changer  $x$  en  $y$ .  
Très utile en bio-informatique et dans les recherches approchées.

On utilise trois opérations d'édition:

- substitution d'une lettre  $a$  de  $x$  par une lettre  $b$  de  $y$  (en des positions données)  
minimun associée à un coût  $\text{Sub}(a, b)$

- suppression d'une lettre de  $x$ , notée  $a$ , de coût  $\text{Del}(a)$ .

- insertion d'une lettre de  $y$ , notée  $b$ , dans  $x$ , de coût  $\text{Ins}(b)$ .

Déf 8 On note  $\text{Lev}(x, y) = \min \{ \text{coût de } \varsigma \mid \varsigma \text{ est une séquence d'éditions changeant } x \text{ en } y \}$ .  
où le coût de  $\varsigma$  est la somme des coûts d'opérations utilisées dans  $\varsigma$ .

Exemple  $x = \text{ACGA}$  et  $y = \text{ATGCTA}$ , où  $\text{Ins} = \text{Del} = 1$  et  $\text{Sub}(a, b) = \begin{cases} 1 & \text{si } a = b \\ 0 & \text{sinon} \end{cases}$   
 $\text{Lev}(x, y) = 3$ , correspondant à un alignement  $(\text{ACG--A})$   
 $\quad \quad \quad (\text{ATGCTA})$

Prop 9  $\text{Lev}$  est une distance sur  $\Sigma^*$

ssi  $\text{Sub}$  est une distance sur  $\Sigma$  et  $\text{Del}(a) = \text{Ins}(a) > 0$  pour chaque  $a \in \Sigma$ .

Note: Un alignement de  $x$  et  $y$  est une façon de visualiser une suite d'éditions changeant  $x$  en  $y$ . Formellement,

c'est un mot  $z$  sur l'alphabet  $(A \cup \{\epsilon\}) \times (A \cup \{\epsilon\}) \setminus \{(\epsilon, \epsilon)\}$  dont la projection sur la première composante (resp. seconde composante) est  $x$  (resp.  $y$ ).

Si  $z = (\bar{x}_1, \bar{y}_1) \dots (\bar{x}_p, \bar{y}_p)$ , on écrit plutôt  $z$  sous la forme  $(\bar{x}_1 \dots \bar{x}_p) (\bar{y}_1 \dots \bar{y}_p)$

Le calcul de la distance d'édition se fait par programmation dynamique:

En notant  $T[i..j] = \text{Lev}(x[1..i], y[1..j])$ ,

on a la propriété suivante

ne pas parler de  
Knuth

→ Utilisé dans les compressions d'images,  
de sons ou de vidéos.

Pb.  
de sécurité

$$\text{On a pour } i, j \geq 2 : T[i, j] = \min \begin{cases} T[i-1, j-1] + \text{Sub}(x[i], y[i]) \\ T[i-1, j] + \text{Del}(x[i]) \\ T[i, j-1] + \text{Ins}(y[i]) \end{cases}$$

En remarquant que seuls deux lignes ou colonnes de  $T$  suffisent au calcul, on a :

Prop 10 On peut calculer  $\text{Ler}$  en un temps  $O(mn)$  et en espace  $O(\min\{m, n\})$ .

Note : Pour exhiber la suite d'édition minimale, il faut y ajouter  $O(m+n)$  en temps et en espace.

### 2) Plus longue sous-suite commune [Grahamore]

En notant  $\text{snc}(x, y)$  la longueur de la plus longue sous-suite commune à  $x$  et  $y$ , on voit que ce problème est une spécialisation du précédent, il revient à enlever la substitution des opérations possibles.

Prop 11 Si  $\text{Del} = \text{Ins} = 1$ , et que par  $s, t \in \Sigma$  on a  $\text{Sub}(s, t) > \text{Del}(s) + \text{Ins}(t) = 2$ ,  
alors  $\text{Ler}(x, y) = n + m - \text{snc}(x, y)$

On peut donc aussi résoudre ce problème par programmation dynamique.  
Supposons dans la suite que  $m \leq n$ .

SSC\_LONGUEUR( $x, y$ ) : // Renvoie la valeur de  $\text{snc}(x[1 \dots i], y)$  par

Pour  $i \in \{0, 1, \dots, m\}$  :  $G_i[i] \leftarrow 0$   $i \in \{1, m\}$ .

Pour  $j \in \{1, n\}$  :

$C_2[j] \leftarrow 0$

Pour  $i \in \{1, m\}$  :

Si  $x[i] = y[j]$  :  $G_i[i] \leftarrow G_i[i-1] + 1$

Sinon :  $G_i[i] \leftarrow \max\{G_i[i], G_i[i-1]\}$

$C_2 \leftarrow G_i$

Retourner  $G_1$

Prop 12 SSC\_LONGUEUR nécessite une complexité

$O(mn)$  en temps et  $O(m)$  en espace.

Thm 13 On peut calculer un plus long sous-mot commun  
à  $x$  et  $y$  en un temps  $O(mn)$  et avec un espace  $O(\min\{m, n\})$ .

### DEVLPPT

### Compression

On cherche à réduire la taille d'un texte en conservant son information.  
Présentons ici l'algorithme de Lempel-Ziv-Welch.

On utilise un "dictionnaire"  $d$ , i.e.

une table qui à chaque entier associe une chaîne de caractères.

Le dictionnaire est généralement initialisé avec  $2k$  cases, où  $k=|\Sigma|$ ,  
et les  $k$  premières cases contiennent les lettres de  $\Sigma$ .

LZV( $T$ ) : //  $T$  est une chaîne de caractères : un mot de  $\Sigma^*$ .

$w = \epsilon$

Pour  $i \in [1, |T|]$  :

Si  $w + T[i] \in d$  : // On a donc une fonction testant si un mot  $s$   
 $L w = w + T[i]$  est dans le dictionnaire  $d$ .

Sinon :

Ajoute  $w + T[i]$  à  $d$

Imprimer  $\text{Code}(w)$

$w = T[i]$

Imprimer  $\text{Code}(w)$

Exemple initial sur un dictionnaire initialisé avec  $\boxed{a \ b \ c \ | \epsilon} \dots$

On aura le code  $0, 1, 2, 4, 7, 0, 9, 10, 0$ .

Et le dictionnaire finira avec  $\boxed{\begin{matrix} a & b & c & ab & ba & abc & cd & bab & bab & co & can & face \\ 0 & 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & 10 & 11 \end{matrix}}$

Prop 14 L'algorithme de décompression n'a pas besoin du dictionnaire  
rendu en entrée.

On peut en avoir l'intuition avec l'exemple : si on veut décoder  $0, 1, 3, 2$ ,  
en sachant que le dictionnaire comme à  $\boxed{a \ b \ c \dots}$ ,  
on a  $0 \leftrightarrow a$ ,  $1 \leftrightarrow b$ . On devine donc que  $d[3] = ab$ .  
Donc  $3 \leftrightarrow ab$ , et  $2 \leftrightarrow c$ . On ait  $ababc$  avant compression.

### Références

- [Cormen] Algorithmes, Cormen, Leiserson, Rivest, Stein
- [Grahamore] Algorithmique du texte, Grahamore, Hancart, decroq
- [Beaugrier] Éléments d'algorithmique, Beaugrier, Berstel, Christienne

## Plus longue sous-suite commune (PLSSC) [Crochemire]

On utilise l'algorithme  $\text{SSC\_LONGUEUR}(x[0..m-1], y[0..n-1])$ ,  
implémentation dynamique de l'idée suivante:

Lemme 1

$$\text{Si } S[i, j] = \begin{cases} 0 & \text{si } i=-1 \text{ ou } j=-1 \\ \text{smc}(x[0..i], y[0..j]) & \text{si } i \in \{0, \dots, m-1\} \\ \text{scc}[0, \dots, n-1] & \text{si } j \in \{0, \dots, n-1\} \end{cases}$$

$$\text{alors pour } i, j \geq 0, \quad S[i, j] = \begin{cases} S[i-1, j-1] + 1 & \text{si } x[i] = y[j] \\ \max(S[i-1, j], S[i, j-1]) & \text{sinon} \end{cases}$$

Preuve

Soyons  $ua = x[0..i]$  et  $vb = y[0..j]$ , où  $a, b \in \Sigma$ .

- Si  $a = b$ , une PLSSC de  $ua$  et  $vb$  se termine par  $a$ !

Autrement, on pourrait la prolonger par  $a$ , absurde par maximalité de la longueur.

$$\text{Donc } S[i, j] = S[i-1, j-1] + 1.$$


- Si  $a \neq b$ , et  $ua$  et  $vb$  possèdent une PLSSC ne se terminant pas par  $a$ ,

$$\text{on a } S[i, j] = S[i-1, j] \quad (*)$$

Par symétrie de  $a$  et  $b$ , on a  $S[i, j] = \max(S[i-1, j], S[i, j-1])$

En reliant  $(i, j)$  à  $(i-1, j-1)$  si  $x[i] = y[j]$ ,  
 à  $(i-1, j)$  si on est dans le cas (\*) du lemme.  
 à  $(i, j-1)$  sinon,

on obtient une ligne joignant  $(-1, -1)$  à  $(m-1, n-1)$  dans  $S$ .



On va chercher la coordonnée  $k$  par laquelle passe la ligne dans la colonne  $[l_{P_2}]$ ,  
pour pouvoir appliquer un algorithme  $\text{SSC}$ , en envoyant une PLSSC, ~~avec~~ avec  
le méthode "diviser pour régner".

$k$  est le plus petit maximisant  $\text{smc}(x[0..k-1], y[0..l_{P_2}-1])$   
 $+ \text{smc}(x[k..m-1], y[l_{P_2}..n-1])$

Pour le trouver, on calcule d'abord la colonne d'indice  $[l_{P_2}-1]$  de  $S$   
par  $\text{SSC\_LONGUEUR}(x, y[0..l_{P_2}-1])$ .

Puis on termine la construction de  $S$  en mémorisant des pointeurs vers la  
colonne du milieu dans  $P_1$  et  $P_2$ .

Les deux tables implémentent la table P vérifiant

$$\begin{cases} \forall i \in \{-1, 0, \dots, m-1\}, \forall j \in \{\lfloor \frac{n}{2} \rfloor - 1, \dots, n-1\}, \\ P[i, j] = k \in \{0, \dots, i+1\} \text{ si} \\ \text{smc}(x[0..i], y[0..j]) = \text{smc}(x[0..k-1], y[0..\lfloor \frac{n}{2} \rfloor - 1]) \\ + \text{smc}(x[k..i], y[\lfloor \frac{n}{2} \rfloor .. j]) \end{cases}$$

Pour  $P[m-1, n-1]$  sera à la clé.

lemme 2

- $\forall i \in \{-1, \dots, m-1\}, P[i, \lfloor \frac{n}{2} \rfloor - 1] = i+1$
- $\forall j \geq \lfloor \frac{n}{2} \rfloor, P[-1, j] = 0$
- $\forall i \geq 0 \text{ et } j \geq \lfloor \frac{n}{2} \rfloor, P[i, j] = \begin{cases} P[i-1, j-1] & \text{si } x[i] = y[j] \\ P[i-1, j] & \text{si } x[i] \neq y[j] \text{ et} \\ & S[i-1, j] > S[i, j-1] \\ P[i, j-1] & \text{sinon} \end{cases}$

Preuve: on se ramène à la définition de P en faisant une récurrence sur  $(i, j)$ , par ordre lexicographique.

• Si  $j = \lfloor \frac{n}{2} \rfloor - 1, y[\lfloor \frac{n}{2} \rfloor - j] = \epsilon$ , donc  $k = i+1$ .

• Si  $i = -1$ , les successeurs de x sont vides donc  $k = 0$ .

• Si  $i \geq 0$  et  $j \geq \lfloor \frac{n}{2} \rfloor$ , supposons  $x[i] = y[j]$  (les autres cas sont similaires)

( lemme 1)  $\text{smc}(x[0..i], y[0..j]) = \text{smc}(x[0..i-1], y[0..j-1]) + 1$

(recurrence)  $\text{smc}(x[0..i-1], y[0..j-1]) = \text{smc}(x[0..k-1], y[0..\lfloor \frac{n}{2} \rfloor - 1]) + \text{smc}(x[k..i-1], y[\lfloor \frac{n}{2} \rfloor .. j-1])$  où  $k = P[i-1, j-1]$

(lemme 1)  $\text{smc}(x[\lfloor \frac{n}{2} .. i], y[\lfloor \frac{n}{2} .. j-1]) = \text{smc}(x[\lfloor \frac{n}{2} .. i-1], y[\lfloor \frac{n}{2} .. j-1]) + 1$

D'où  $P[i, j] = k = P[i-1, j-1]$

Ecrivons enfin l'algorithme SSC.

La preuve de correction découle essentiellement des lemme 2, et de la justification de SSC-LONGUEUR.

$SSC(x, y)$ :

Si  $m = 0$  et  $x[0]$  apparaît dans  $y$ : Renvoie  $x[0]$

Sinon, si  $n = 1$  et  $y[0]$  apparaît dans  $x$ : Renvoie  $y[0]$

Sinon, si  $m = 0$  ou  $m = 1$  ou  $n = 0$  ou  $n = 1$ : Renvoie  $\epsilon$

Skipped

$C_1 \leftarrow SSC\_LONGUEUR(x, y[0.. \lfloor \frac{m}{2} \rfloor - 1])$

Pour  $i \in \{1, \dots, m-1\}$ :  $P_1[i] \leftarrow i+1$

Pour  $j \in \{ \lceil \frac{n}{2} \rceil, \dots, n-1 \}$ :

$C_2[-1], P_2[-1] \leftarrow 0$

Pour  $i \in \{0, \dots, m-1\}$ :

Si  $x[i] = y[j]$ :

$C_2[i] \leftarrow C_2[i-1] + 1$

$P_2[i] \leftarrow P_1[i-1]$

Sinon, si  $C_1[i] > C_2[i-1]$ :

$C_2[i] \leftarrow C_1[i]$

$P_2[i] \leftarrow P_1[i]$

Sinon

$C_2[i] \leftarrow C_2[i-1]$

$P_2[i] \leftarrow P_2[i-1]$

$C_1 \leftarrow C_2$  /  $P_1 \leftarrow P_2$

$k \leftarrow P_1[m-1]$

$U \leftarrow SSC(x[0..k], y[0.. \lfloor \frac{n}{2} \rfloor - 1])$

$V \leftarrow SSC(x[k..m-1], y[\lceil \frac{n}{2} \rceil..n-1])$

Retourner  $U \cdot V$

Par les complexités:  $SSC$  s'exécute en temps  $O(mn)$  dans un espace  $O(m)$ .

Preuve: Si  $E(m, n)$  désigne la complexité de  $SSC$  (par  $\begin{cases} 1 & \text{si } m = 1 \\ 1 & \text{si } n = 1 \end{cases}$ ) alors  $E(m, n) = O(mn) + E(k, \lfloor \frac{n}{2} \rfloor) + E(m-k, n-\lceil \frac{n}{2} \rceil)$ .

Ainsi, comme  $O(k \lfloor \frac{n}{2} \rfloor) + O((n-k)(n-\lceil \frac{n}{2} \rceil)) = O(\frac{mn}{2})$  et

que  $\sum \frac{m^n}{2^n} \leq 2mn$ , on a  $E(m, n) = O(mn)$ .

Le mémorail nécessaire consiste en la taille de  $C_1, C_2, P_1$  et  $P_2$ , le tout en  $O(m)$ . En effet, comme les appels récursifs n'utilisent pas les informations stockées dans ces tables, on peut réutiliser le même espace dans la suite du calcul.

## Questions :

1) Recherche de motif : est-ce qu'on peut détecter l'occurrence d'une expression régulière ?

↳ OUI  $\rightarrow$  automate

Pb: pour qu'il soit déterministe MIS: 2<sup>e</sup> état  $\rightarrow$  BAC

↳ Beaugnier = méthode - limite en la taille de l'apr. mais avec des bonnes pp'tés. ( $\rightarrow$  automate normalisé → à partir d'un état initial  $\xrightarrow{\alpha} \text{X}$  et  $\xrightarrow{\epsilon} \text{Y}$ ) par plus de 1 état initial

↳ Plus courte sur séquence commune  $\rightarrow$  un mot lequel court possible, qui inclue les deux mots de départ ( $x_1 \dots x_n, y_1 \dots y_m$ )

AT GCTA  
A CGA  
PLSSC  $\rightarrow$  AGA.  
 $\beta_1 \dots \beta_k$

A T G C T A  
A C G A  $\rightarrow$  ATC GCTA  
(ou ACT GCTA)

Algo:

$w \in \Sigma^*$   
tant que  $i < |z|$   
tant que  $x_i \neq z_i$ :

$w = w + x_i$   
 $i = i + 1$

tant que  $y_j \neq z_j$ :

$w = w + y_j$   
 $j = j + 1$

$w = w + z$   
 $i++$ ;  $j++$

$w = w + x[i \dots m] + y[i \dots m]$   
retourne  $w$ .

$\leftarrow$  DVPT PLSSC non optimisé  
+ 1<sup>re</sup> application

DVPT : automate minimal  
des occurrences et

DVPT : Rabin Karp

# Distance de Levenshtein sur les mots

Référence : M. CROCHEMORE, W. RYTTER  
*Text Algorithms*

2015-2016

Étant donnés deux mots  $X = x_1 \cdots x_m$  et  $Y = y_1 \cdots y_n$  sur un alphabet  $\Sigma$ , on cherche à savoir quelle est distance de Levenshtein entre  $X$  et  $Y$ , à savoir le coût minimal pour aller de  $X$  à  $Y$  en effectuant les opérations élémentaires suivantes :

- suppression d'un caractère de  $X$ ,
- ajout d'un caractère de  $X$  dans  $Y$ ,
- substitution d'un caractère de  $X$  dans  $Y$ .

On note  $m$  la longueur de  $X$ ,  $n$  celle de  $Y$  et  $X[i]$  le  $i$ -ème caractère de  $X$ . On suppose  $n \geq m$ .

Considérons  $G$ , un graphe composé de  $m \times n$  nœuds notés  $(i, j)$  (pour  $i \in [0, m]$  et  $j \in [0, n]$ ). Chaque nœud  $(i, j)$  est relié aux nœuds  $(i + 1, j)$  et  $(i, j + 1)$  par une arête de poids 1 et au nœud  $(i + 1, j + 1)$  par une arête de poids  $\delta(X[i+1], Y[j+1])$ . La distance de Levenshtein entre  $X$  et  $Y$  est égale au poids du plus court chemin dans  $G$  reliant les sommets  $(0, 0)$  et  $(m, n)$ .

Soit  $EDIT$  un tableau de taille  $m \times n$  défini par :

- $\forall i \in [0, m], EDIT[i, 0] = i$ ,
- $\forall j \in [0, n], EDIT[0, j] = j$ ,
- $\forall i \in [1, m], j \in [1, n], EDIT[i, j] = \min(EDIT[i - 1, j] + 1, EDIT[i, j - 1] + 1, EDIT[i - 1, j - 1] + \delta(X[i], Y[j]))$ .

La distance de Levenshtein entre  $X$  et  $Y$  est alors égale à  $EDIT(m, n)$ , la valeur  $EDIT(i, j)$  représentant la distance minimale entre  $(0, 0)$  et  $(i, j)$  dans  $G$ .

**Theorem 1** *La procédure  $EDIT$  a une complexité en temps de  $\mathcal{O}(m \times n)$  et en mémoire de  $\mathcal{O}(m)$ .*

## Proof

Dans  $EDIT$ , on a deux boucles "pour" imbriquées, et dans chacune de ces boucles des opérations en  $\mathcal{O}(1)$ . D'où la complexité en  $\mathcal{O}(m \times n)$ .

On peut toutefois se contenter de garder en mémoire les informations sur la colonne (ou la ligne) actuelle ainsi que la précédente à tout moment du calcul, réduisant ainsi la complexité en mémoire à du  $\mathcal{O}(m)$ . Ceci dit, garder tout le tableau en mémoire nous permet de reconstruire les opérations pour passer de  $X$  à  $Y$ .  $\square$

---

**Algorithm 1** EDIT

---

```
m ← X
n ← Y
for i = 1 to m do
    EDIT[i, 0] ← i
end for
for j = 0 to n do
    c[0, j] ← j
end for
for i = 1 to m do
    for j = 1 to n do
        if  $x_i = y_j$  then
            delta ← 0
        else
            delta ← 1
        end if
        EDIT[i, j] ← min(EDIT[i − 1, j] + 1, EDIT[i, j − 1] + 1, EDIT[i − 1, j − 1] + delta)
    end for
end for
return EDIT[m, n]
```

---

**Example 1** On cherche à comparer les chaînes NICHE et CHIENS. Le tableau construit par EDIT est :

		C	H	I	E	N	S
	0	1	2	3	4	5	6
N	1	1	2	3	4	4	5
I	2	2	2	2	3	4	5
C	3	2	3	3	3	4	5
H	4	3	2	3	4	4	5
E	5	4	3	3	3	4	5

La distance entre NICHE et CHIENS est de 5 et une façon de passer de l'un à l'autre est de supprimer les lettres N et I de NICHE pour obtenir CHE puis de rajouter les lettres I, N et S aux endroits adéquats.