

Notation: On notera l'alphabet sur lequel on travaille Σ , supposé fini. Une tente sera noté $T = t_0 t_1 \dots t_{n-1}$; où $t_i \in \Sigma, i \in [0; n-1]$, $t_i \in \Sigma$ et n est la longueur de la tente (nombre de caractères). On note de même un motif $M = m_0 \dots m_{k-1}$ de longueur k . k et n sont supposés toujours finis.

I Algorithmes de recherche de motif dans un texte

Problème: Soit un texte T et un motif M . On cherche le plus petit indice $j \in [0; n-1]$ où n est la longueur du texte tel que $t_j t_{j+1} \dots t_{j+k-1} = M$, k la longueur du motif.

Algorithme 1: Algorithme naïf

Entrée: T texte, M motif

Sorité: indice j minimal tel que $t_j t_{j+1} \dots t_{j+k-1} = M$

Recherche naïve ($T; M$)

$| n, k = \text{longueur}(T), \text{longueur}(M)$

Pour $j = 0$ à $n-k$:

| Si $M = t_j t_{j+1} \dots t_{j+k-1}$:

| renvoyer j

Renvoyer "erreur: T ne contient pas M "

La complétenet temporelle en pire cas est en $O(nk)$

→ Exemple 2:

Si on cherche aab dans $aaaaaa\dots aab = T$
grand nombre de a

On voit apparaître le coplément

Remarque 3: Dans le cas de tente en français, on peut estimer que le texte ne contient pas beaucoup de préfixes du motif. Dans le cas de la recherche de séquence dans un génome, on peut atteindre la complétenet en pire cas.

Algorithme 4: Rabin-Karp.

On suppose $\Sigma = [0; n-1] \subset \mathbb{N}$.

Principe: On va faire un pré-traitement sur T . Si on cherche un motif de taille k , on va créer un tableau T de taille $n-k$ où la case i contient $t_i t_{i+1} \dots t_{i+k-1}$. Soit $m = \sum_{i=0}^{n-k} m_i$. Il suffira alors de regarder pour les i tel que $T[i] = m$ si $M = t_i t_{i+1} \dots t_{i+k-1}$

Complétenet: Ce paradigme est en pratique plus efficace que la recherche naïve mais, en pire cas, la complétenet est en $O(nk)$. De plus, il faut un tableau de taille $n-k$ en mémoire.

Exemple 3: Soit $\Sigma = [0, 1]$. On cherche $M = 011$.

Si $T = (002) \dots (002) 011$,

on voit apparaître la complétenet en pire cas : $O(nk)$.

Définition 6: Soit T un texte; M un motif sur un alphabet Σ .


On définit l'automate des occurrences par:

- l'alphabet Σ
- $Q = \{0, \dots, h\}$ les états, où h est la longueur du motif.
- $\{0\}$ l'état initial
- $\{h\}$ l'état final
- S la fonction de transition, tel que $\forall q \in Q, \forall a \in \Sigma$, $S(q, a)$ renvoie l'indice j minimal tel que $m_0 \dots m_{j-1}$ soit préfixe de M et suffixe de $m_0 m_1 \dots m_{q-1} a$.

Remarque 7: Un tel objet a besoin d'un espace mémoire en $O(|\Sigma|k)$

Exemple 8: Soit $P = ababaca$; $\Sigma = \{a; b; c\}$.

L'automate des occurrences associées est



Si en 1, 2, 3, 4, 6; on lit un c , on est renvoyé à l'état 0. Une fois en 7, l'automate s'arrête.

Algorithme 5: Morris-Pratt

Morris-Pratt ($T; M; \Sigma$)

$S = \text{creer_delta}(M; \Sigma)$

$n = \text{longueur}(T)$

$q = 0$

Pour $i = 0$ à $n-1$:

| $q = S(q, T[i])$

| si $q = m$

| renvoyer $i-k$

renvoyer "T ne contient pas M"

La complétenet hors pré-traitement est linéaire en la hauteur du texte. Le pré-traitement (contenu dans `creer_delta`, qui renvoie la fonction S de transition de l'automate des occurrences associé à M) nécessite une place mémoire en $O(|\Sigma|M)$ et s'effectue en $O(|\Sigma|^2)$ opérations.

creer_delta($M; \Sigma$):

$h = \text{longueur}(M)$

Pour $q = 0$ à m
pour toute $a \in \Sigma$

$h = \min(m+1, q+2)$

répéter

$h = h - 1$

jusqu'à $M_h \sqsupseteq M_q a$

$\delta(q, a) = h$

retourner δ

On note " $M_h \sqsupseteq M_q a$ " le fait que $M_0 \dots M_{h-1}$ soit suffisante de faire $\dots M_{q-1} a$.

Les 2 premières boucles complètes pour $(m+1|\Sigma)$ opérations. La boucle répétée peut se faire au plus $q \leq h$ fois, la vérification $M_h \sqsupseteq M_q a$ est faite en au plus h opérations.
→ Complexité en $O(h^3 |\Sigma|)$.

Remarque 10 (admis): Il est possible de faire tomber la complexité de creer_delta à $O(h |\Sigma|)$ opérations.

Dev 1: Algorithme de Knuth-Morris-Pratt, validité.
L'algorithme a une complexité spatiale en $O(h)$, temporelle en $O(n)$.

Remarque 11: Les algorithmes Morris-Pratt et Knuth-Morris-Pratt peuvent se généraliser au cas d'ensembles de mots finis.

II Distance d'édition et recherche approchée de motif

Exemple 12: Si la recherche n'est pas sensible à la casse, on peut retrouver "Abc" au lieu de "abc". On va généraliser la recherche approchée de motif.

Definition 13: On pose les fonctions suivantes:

Sub : $\Sigma \times \Sigma \rightarrow \mathbb{R}^+$; où sub(a;b) est le coût de substitution de la lettre a par b. Sub(a;a) = 0, $(a;b) \in \Sigma^2$

Del: $\Sigma \rightarrow \mathbb{R}^+$; où del(a) est le coût de la suppression de a, $a \in \Sigma$

Ins : $\Sigma \rightarrow \mathbb{R}^+$; où Ins(a) est le coût d'insertion de la lettre a.

Definition 14: On note $\forall m, y \in \Sigma^*$, mots sur Σ , $\Sigma^n y$ l'ensemble des suites d'opérations menant du mot m au mot y .

C'est non vide, car on peut supprimer toutes les lettres de m puis ajouter toutes celles de y .

Definition 15: Lev : $\Sigma^* \times \Sigma^* \rightarrow \mathbb{R}^+$

$(m; y) \mapsto \min(\text{cost de } T, \tau \in \Sigma^y)$

est appelé distance d'édition.

Théorème 16: Lev est une distance sur Σ^* si et seulement si Sub est une distance sur Σ

• $\forall a \in \Sigma$, del(a) = Ins(a) > 0

Definition 17: Un alignement entre x et $y \in \Sigma^*$ est un mot z sur l'alphabet $(\Sigma \cup \{\epsilon\})^2 / \{\langle \epsilon, \epsilon \rangle\}$ dont la projection sur la première composante est x et y sur la deuxième composante. On note $z = (\frac{x_0}{y_0} \dots \frac{x_n}{y_n})$

Exemple 18: Si $x = ACGA$; $y = ATGCTA$, un alignement est $z = \begin{pmatrix} A & C & G & \epsilon & \epsilon & A \\ A & T & G & C & T & A \end{pmatrix}$. $\begin{pmatrix} & & & & & \end{pmatrix}$ représente une suppression. $\begin{pmatrix} & & & & & \end{pmatrix}$ représente l'ajout. $\begin{pmatrix} & & & & & \end{pmatrix}$ représente la substitution.

Definition 19: Le coût d'un alignement est la somme des coûts de chaque opération représentée.

Definition 20: Un alignement z entre $m, y \in \Sigma^*$ est dit optimal si son coût est $\text{Lev}(m, y)$.

Dev 2 (Bashien) Calcul de l'alignement optimal entre 2 mots sur Σ^*

Problème: Soit un texte T , un motif M , de longueurs respectives n et k . On souhaite trouver les séquences M' , de longueur $k' \geq k$, avec un nombre minimal de différences, i.e où $\text{Lev}(M, M') \leq d$, d est fixé, $d \leq k$. On suppose que toute substitution, suppression et ajout coûte 1.

Dev 3 (Rémi) Recherche des facteurs de T à une distance au plus k de M par la programmation dynamique. Amélioration avec les cases P-spéciales. Complexité.

Exemple 2.1: Ce problème convient dans le cas de recherche de séquences ADN dans un génome en tenant compte d'éventuelles mutations.

III Compression

Remarque 2.2: On ne peut pas compresser indéfiniment sans perte d'information. On ne peut pas forcément stocker l'information de n bits en $n-1$ bits.

Définition 2.3: L'algorithme de Lempel-Ziv (LZ) est un algorithme de compression par substitution de facteurs. Il remplace des séquences par l'indice des séquences dans un dictionnaire. Il fonctionne en une seule lecture de texte.

Exemple 2.4: "Un bon gars est un gars bon." donnera alors "Un bon gars est [1] [3] [2]."

Remarque 2.5: Cette base d'algorithme est aujourd'hui majoritairement utilisée

Algorithme 2.6 : LZ 77


Basée sur une fenêtre qui glisse de gauche à droite sur le texte, divisée en 2 parties: Une qui contient le dictionnaire, l'autre qui rencontre le texte en premier (toupon de lecture). Initialement, la première partie est vide, la dernière contient T . A chaque itération, on cherche la plus longue séquence préfixe de T contenue dans le dictionnaire, codé par (i, j, c) où i est la distance entre le début du mot et la position de la répétition dans le dictionnaire.

$\rightarrow j$ est la longueur de la répétition

$\rightarrow c$ est le premier caractère du mot différent du caractère correspondant dans le dictionnaire.

La fenêtre couvre de $j+1$ caractères.

Exemple 2.7: On applique LZ 77 à abcdefabcdefabcdefabcdef. On obtient:



Algorithm 2.8 Lempel-Ziv-Welch (LZW)

Il consiste à ne coder que l'indice dans le dictionnaire. Il est nécessaire d'avoir un dictionnaire initial (Par exemple la table ASCII). On remplace chaque groupe de caractères déjà connue par son code et on ajoute au dictionnaire un nouveau groupe formé par ce groupe suivi du prochain caractère.

LZW-Comp (T , dictionnaire)

chaine $\leftarrow \emptyset$

Tant que T n'est pas à la fin

de T
lire c caractère de T

Si chaine + c dans le dictionnaire

chaine \leftarrow chaine + c

Sinon

afficher code(chaine)

ajout chaine + c au dictionnaire

chaine $\leftarrow c$

LZW-decompression (code, dico)

prec \leftarrow lire-objet(code)

Tant que T n'est pas à la fin du code

cour \leftarrow lire-objet(code)

Si cour & dictionnaire

chaine \leftarrow trad(cour)

Sinon

chaine \leftarrow trad(prec)

c \leftarrow premier-caractère(chaine)

chaine \leftarrow chaine + c

afficher chaine

ajout chaine au dictionnaire

prec \leftarrow cour

Pour la compression, le si - Sinon gère le seul cas problématique: la répétition de chaîne (Cas où cour & dictionnaire). On part avec les mêmes dictionnaires initiaux.

IV Codes correcteurs

Problème: On veut vérifier algorithmiquement si un message reçu par un ordinateur est correct.

Exemple 2.9: Code de parité

On envoie un message de n bits. On va envoyer un $n+1$ ième bit de sorte à ce que la somme des éléments soit pair.

010 \rightarrow 0101 || Permet de détecter une erreur

011 \rightarrow 0110 || mais ne permet pas de corriger.

Exemple 3.0: Code de répétition.

Soit m le message envoyé. On va répéter 3 fois m .

1001 \rightarrow 1001 1001 1001

Si on envoie 1000 1001 1001, on peut détecter et corriger l'erreur.