

907 Algorithmique du texte. Exemples et applications

I Recherche de motifs

1) Effectif et algorithme naïf

On cherche à trouver les occurrences d'une

chaîne de caractères $M[1..m]$ dans un texte

$T[1..n] \ (m \leq n)$

L'algorithme naïf associe entre les méthodes
deux des fenêtres glissantes :

$T : a b c a b c a b c a b c$

$M : \rightarrow \rightarrow a b c a$

Recherche naïve (P)

1 tour S de 0 à $m-m$

ni $\rho[1..m] = T[S+1..S+m]$


afficher : " M apparaît à la position S

Complexité temporelle : $O((m-m+1)m)$

2) Automates des occurrences, Knuth-Morris-Pratt

Idee: On construit un automate reconnaissant
le motif M et on rend T en motif d'entrée

DPT



La construction de la fonction de transition ne facilite
à l'aide de la fonction suffisante $\sigma(q) = \text{motif}[q..n]$, où est
retour de $M[q..n]$ en avant :

$$\delta(q, a) = \sigma(M[q..n]a)$$

Complexité temporelle :

Construction de l'automate $O(m|\Sigma|)$

Recherche : $O(n)$

Amélioration : algorithme de Knuth-Morris-Pratt

Principe: On écrit le calcul de la fonction de
transition en introduisant une nouvelle fonction
réécoulée en temps linéaire :

$\tau(i) > \text{la longueur du plus long préfixe}$
 $\text{de } M \text{ qui est un suffixe propre de } M[i..n]$

On écrit le algorithme :

KMP(T, M)

$q = 0$

1 tour (de 1 à n)

2 tant que $q > 0 \wedge \delta(\tau(q), T[i]) \neq T[i]$

3 $q = \tau(q)$

4 $q = q + 1$

5 $\delta(M[q..n]) = T[i]$

6 $q = q + 1$

7 $q = m$

8 afficher "le motif apparaît à la position $i-m$

9 $q = \tau(q)$

5) Algorithme de Boyer-Moore

Principe: On cherche une racine de la méthode des généralisations qui commence par comporter peu de motifs pour toute à chaque tentatives.



Notons z le plus long suffixe commun à M et $T[0, \dots, k]$.

Si $z \neq M$, on doit effectuer un décalage :

- si $k-z$ se trouve dans M , on élimine son occurrence dans T avec son occurrence la plus à droite dans M

sinon on déplace le plus grand préfixe de M qui n'a pas suffis de z .

Req: calcul du décalage à effectuer est indépendant des hôtes, et peut être réalisé à partir de M .

Surfouït temporelle

Préférentiellement : $O(m|\Sigma|)$

Recherche : $O(n)$

4) Table des suffices

Principe: On construit une table suivi d'une recherche qui contient les suffices de T et on recherche sur dichotomie.

Complexité de la recherche : $O(n \log n)$.

Le mémorlement du hôte ne fait à la suite d'une] OVT

5) Table d'applications

Boyer-Moore est l'algorithme le plus communément utilisé (dans F / grep)

La table des suffices ne tente à des recherches multiples sur un même hôte.

II Comparaison de chaînes de caractères

1) Plus longue sous séquence commune

• Soit $X[1 \dots m]$ & $Y[1 \dots m]$ deux chaînes de caractères d'une plus longue séquence commune (PLSC) de X et Y et une chaîne $Z[1 \dots k]$ telle qu'il existe φ, σ croissantes $\tau_q \forall i \in Z[0] = X[\varphi(i)] = Y[\sigma(i)]$.

• Propriété: Forme structure d'une PLSC

• si $X[m] = Y[m]$, $Z[k] = X[m] = Y[m]$ et $Z[1 \dots k-1]$ est une PLSC de $X[1 \dots m-1]$ et $Y[1 \dots m-1]$

• sinon, si $Z[k] \neq X[m]$, Z est une PLSC de Y et $X[1 \dots m-1]$

• si $Z[k] \neq Y[m]$, Z est une PLSC de X et $Y[1 \dots m-1]$

De cette propriété, on déduit un algorithme de programmation dynamique permettant de calculer une PLSC, pour une comparaison ponctuelle en $O(m \cdot m)$

2) Durée de l'édition

On cherche à poser une chaîne X à une chaîne Y

- en nombre minimum d'opérations de type :

- remplacer un caractère par un autre
- ajouter ou supprimer un caractère
- changer un caractère

On obtient un algorithme de programmation dynamique calculant la durée le plus court des opérations de X et Y en se servant du calcul de la durée le plus court des préfixes plus petits.

Exemple : Trouver la plus courte chaîne à partir de POMME et POIRE

| | P | O | M | M | E |
|---|---|---|---|---|---|
| O | 0 | 1 | 2 | 3 | 4 |
| P | 1 | 0 | 1 | 2 | 3 |
| O | 2 | 1 | 0 | 1 | 2 |
| R | 3 | 2 | 1 | 0 | 1 |
| I | 4 | 3 | 2 | 1 | 0 |
| E | 5 | 4 | 3 | 2 | 1 |

La plus courte chaîne est POME

Exercice : Trouver la plus courte chaîne à partir de CHAT et CHATON

Exercice : Trouver la plus courte chaîne à partir de CHAT et CHATON

Algorithmus : - correction orthographique

- commande "diff"

3) Application à la recherche approchée : recherche avec

la différence

On cherche à trouver la recherche d'un motif M dans un texte T , mais on ne permet de numérotage des occurrences qui diffèrent de M par au plus k opérations.

Pour cela, on applique une version de l'algorithme de recherche d'édition :

III) Compression : Codage de Huffman

Problème : On considère un ensemble de caractères dont il existe une fréquence d'apparition. On cherche un codage préfixe optimal de cet ensemble, c'est à dire une fonction associant à chaque caractère une suite binaires telle que :

- aucune suite n'est préfixe d'une autre
- le nombre moyen de caractères binaires soit minimal
- on ait les codages préfixes.

On utilise pour cela l'algorithme glouton de Huffman.

On construit un arbre de feuilles distinguées par les caractères et leur fréquence d'apparition.

On fait que si on a au moins 2, on choisit les deux plus petits, que l'on combine pour former un arbre dont la racine est équivalente à la somme des fréquences.

$$E_0 = \{(P, 5), (O, 9), (M, 12), (R, 13), (L, 16), (A, 45)\}$$

$$\begin{aligned} E_1 &= \{(P, 5), (O, 9), (M, 12), (R, 13), (L, 16), (A, 45)\} \\ &\quad \cup \{(O, 9), (M, 12)\} \end{aligned}$$

$$\{(P, 5), (R, 13), (L, 16), (A, 45)\}$$


$$\{(P, 5), (R, 13), (L, 16), (A, 45)\}$$

$$\{(P, 5), (R, 13), (L, 16), (A, 45)\}$$

- la règle d'initialisation de T contient 0 tout court, pour permettre la recherche de rendre en compte les occurrences de M partout dans T .
- à la dernière étape, on a "lu" M dans T , aussi toutes les cases de cette ligne indiquent une durée inférieure à la suivante par l'ensemble d'occurrences encadrées.

Automate des occurrences

P motif de longueur m , T texte de longueur n



détermiste $Q = \{0..m\}$, $q_0 = 0$, $F = \{m\}$, $\delta(q, a) = \sigma(P_q a)$
 où $\sigma(x) = \max \{k \in \{0..m\} \mid P_k \sqsupseteq x\}$
 ↳ bien défini car $P_0 = \epsilon \sqsupseteq x \quad \forall x \in \Sigma^*$.

Thm: A reconnaît $\Sigma^* P$ et A est minimal.


Mention plus précisément que : $\forall i \in \{0..n\}, \delta(q_0, T_i) = \sigma(T_i)$.

↳ qui donnera le résultat car :

il y a une occurrence de P qui finit à la position i dans T

ssi $P \sqsupseteq T_i$ ssi $\sigma(T_i) = m$.

Lm 1 $x \sqsupseteq y \Rightarrow \sigma(x) \leq \sigma(y)$



$P_{\sigma(x)} \sqsupseteq y$ donc $\sigma(x) \leq \sigma(y)$
 par maximilité de $\sigma(y)$.


Lm 2 $\sigma(xa) \leq \sigma(x) + 1$

Si $\sigma(xa) = 0$ ok.



$P_{\sigma(xa)-1} \sqsupseteq x \Rightarrow \sigma(xa) - 1 \leq \sigma(x)$
 par maximilité de $\sigma(x)$.

$$\text{Lm 3} \quad \sigma(xa) = \sigma(P_{\sigma(x)} a)$$



$$\underbrace{P_{\sigma(x)} a}_{\alpha} + a \geq x a \Rightarrow \sigma(x) \leq \sigma(xa) \quad (\text{lm 1})$$

* $\underbrace{P_{\sigma(xa)}}_{\beta} + a \geq x a$ Mais $|\alpha| = \sigma(x) + 1 \geq |\beta| = \sigma(xa)$
 (lm 2)

donc $\beta \geq x$

d'où $\sigma(xa) \leq \sigma(x)$ par maximalité
 de $\sigma(a)$.

Conclusion rec sur i

$$i=0 \quad d(q_0, \varepsilon) = q_0 \quad \text{ok}$$

$$\begin{aligned} i \rightarrow i+1 \quad d(q_0, T_{i+1}) &= d(\underbrace{d(q_0, T_i)}_{\sigma(T_i)}, a_{i+1}) = \sigma(P_{\sigma(T_i)} a_{i+1}) \\ &= \sigma(T_i a_{i+1}) \quad (\text{lm 3}) \\ &= \underline{\sigma(T_{i+1})}. \end{aligned}$$

Minimalité Pour $k \in \{0..m\}$ on pose $P = P_k Q_k$,
 on a $d(q_0, P_k) = k$.

Soient $i < j \in \{0..m\}$. MQ $i \neq j$, c'est à dire $L_i \neq L_j$.

* $d(q_0, P) = d(\underbrace{d(q_0, P_j)}_m, Q_j)$ d'où $Q_j \in L_j$.

* $d(q_0, P_i Q_j) = d(i, Q_j) \neq m$ car $|P_i Q_j| < m$

d'où d minimal.

Tri des Suffixes

Naïf: $O(n \times n \log n)$
 durée \approx n^2 comparaisons
 1 comparaison

$w \in \Sigma^*$, $|w| = n$, $S = \{w_i \mid i \in \{1..n\}\}$, $\Sigma = \text{alph}(w)$.
 $w \boxed{\quad | w_i \quad}$ le i^{e} suffixe
 donc $|\Sigma| = O(n)$

On cherche à trier S par ordre lexicographique : on veut $\pi \in \Omega_n$ tq $w_{\pi(i)}$ soit le i^{e} élément de S trié.

k premières lettres

On note $w[i..k] = w[i..n]$ si $k \geq n$.

$S_k = \{w[i..i+k-1] \mid i \in \{1..n\}\}$ ($S_n = S$, $|S_k| \leq |S| = n$).

$R_k[i] =$ le rang de $w[i..i+k-1]$ dans S_k trié, $R_k[i] = 0$ si $i > n$

$\pi_k \in \Omega_n$ tq $w[\pi_k(i).. \pi_k(i)+k-1]$ soit le i^{e} élément de S_k

↳ à rang égal : stable vis à vis de π_{k-1}

Rq: $R_k[i] \in \{1..|S_k|\}$ alors que $\pi_k(i) \in \{1..n\}$

Ideé: si $|S_k| = n = |S|$, $R_k = R_n$ a n élts \neq
 donc $\pi = R_n^{-1}$

$k=1$ $R_1[i] =$ rang de $w[i]$ dans Σ

$k \rightarrow 2k$ Lm de dédoublement: $R_{2k}[i]$ est le rang de $(R_k[i], R_k[i+k])$ dans la liste couples $(i \in \{1..n\})$ triée.

Preuve $w[i..i+2k-1] = \underbrace{w[i..i+k-1]}_{w(i)} \underbrace{w[i+k..i+2k-1]}_{v(i)}$

$w(i) < w(j)$ ssi $w(i)v(i) < w(j)v(j)$

ssi $(w(i), v(i)) < (w(j), v(j))$

ssi $(R_k[i], R_k[i+k]) < (R_k[j], R_k[j+k])$

d'où le résultat.

Rq importante : Poser $R[\Sigma_i] = 0$ pour $i > n$ revient à considérer le mot $w\alpha^\infty$ où α est une lettre inférieure à toutes les autres \rightarrow compatible avec l'ordre lexicographique.

Ex $w = ababca$, $n = 6$, $S = \{w, babca, abca, bca, ca, a\}$

* $S_1 = \{a, b, c\}$

$$R_1 = \boxed{1|2|1|2|3|1} \rightarrow (12)(21)(12)(23)(31)(10)$$

$$\pi_1 = \boxed{1|3|6|2|4|5}$$

* $S_2 = \{ab, ba, bc, ca, c\}$

$$R_2 = \boxed{2|3|2|4|5|1} \rightarrow (22)(34)(25)(41)(50)(10)$$

$$\pi_2 = \boxed{6|1|3|2|4|5}$$

* $R_4 = \boxed{2|4|3|5|6|1}$

$$\pi = \pi_4 = \boxed{6|1|3|2|4|5}$$

Algorithme

Utilise le tri par dénombrement :

$TRID(\pi_1, n, R)$ renvoie $\pi_2 \in \Omega_n$ tq $R[\Sigma_{\pi_2(i)}]$ est le $i^{\text{ème}}$ élément de $\{R[\Sigma_i] | i \in \{1..n\}\}$ et stable vis à vis de π_1 ($\text{si } R[\Sigma_{\pi_1(i)}] = R[\Sigma_{\pi_1(j)}] \text{ avec } \pi_1(i) < \pi_1(j) \text{ alors } \pi_2(i) < \pi_2(j)$).
 Ce qui s'exécute en $\Theta(n^2)$ (en supposant $\{R[\Sigma_i]\} \subseteq \{1..n\}$).

$TRID(\pi_1, n, A) =$

| | | |
|---------------------------------|--|-----------------------------|
| <u>pour</u> $i = 1$ à n faire | $C[\Sigma_i] \leftarrow 0$ | $\ n = \max_i R[\Sigma_i]$ |
| <u>pour</u> $j = 1$ à n faire | $C[A[\pi_1(j)]] \leftarrow C[A[\pi_1(j)]] + 1$ | $\ n = w $ |
| <u>pour</u> $i = 1$ à n faire | $C[\Sigma_i] \leftarrow C[\Sigma_i] + C[\Sigma_{i-1}]$ | |
| <u>pour</u> $j = n$ à 1 faire | | |
| | $\pi_2(j) \leftarrow C[A[\pi_1(j)]]$ | |
| | $C[A[\pi_1(j)]] \leftarrow C[A[\pi_1(j)]] - 1$ | |

$\boxed{\Theta(n)}$

TRI - SUFFIXES (w) =

- $k \leftarrow 1$
- $\pi \leftarrow \text{TRID}(\text{id}, n, w[])$ $\quad O(n)$
- $\alpha \leftarrow 1, R_1[\pi(1)] \leftarrow 1$
- pour $i=2$ à n faire
 - | si $w[\pi(i)] \neq w[\pi(i-1)]$ alors $\alpha \leftarrow \alpha + 1$ $\quad) O(n)$
 - | $R_1[\pi(i)] \leftarrow \alpha$
- tant que $\alpha < n$ faire
 - | $\pi \leftarrow \text{TRID}(\pi, n, R_{2k}[\cdot+k])$ $\quad) O(n)$
 - | $\pi \leftarrow \text{TRID}(\pi, n, R_k)$
 - | $\alpha \leftarrow 1, R_{2k}[\pi(1)] \leftarrow 1$
 - | pour $i=2$ à n faire
 - | | si $(R_k[\pi(i)], R_k[\pi(i)+k]) \neq (R_k[\pi(i-1)], R_k[\pi(i-1)+k])$ alors $\alpha \leftarrow \alpha + 1$ $\quad O(n)$
 - | | $R_{2k}[\pi(i)] \leftarrow \alpha$
 - | $k \leftarrow 2k$
- renvoyer π $\quad \square$

Il y a au pire $\log n$ itérations de la boucle tant que

$$\Rightarrow \boxed{O(n \log n)}$$