

Automate des occurrences [Lec 915-921]

Soit Σ un alphabet $\neq \emptyset$, $t \in \Sigma^*$ un texte et $m \in \Sigma^*$ un mot que l'on souhaite rechercher dans t .

notation def On note \mathcal{P} l'ensemble des préfixes de m


De plus $\forall u \in \Sigma^*$, on note $\sigma_m(u) =$ le plus long suffixe de u qui soit préfixe de m .

def Automate des occurrences

on considère l'automate $A_m = (\mathcal{P}, \Sigma, \delta, \{\epsilon\}, \{m\})$

avec $\forall p \in \mathcal{P}, \forall a \in \Sigma, \delta(p, a) = \sigma_m(pa)$

ex Pour le mot $m = aba$, on a $A_m =$



interprétations:

état = jusque là on a reconnu le préfixe

transitions: soit on garde le préfixe reconnu,

soit on abandonne l'ancien mais pas + que mémoire.

Simuler la recherche avec $t = aabbabab$

th A_m reconnaît le langage $L = \Sigma^* m$. De plus, il est minimal pour ce langage L

dém. On étend comme d'habitude la fonction de transition δ aux les lettres

$$\text{en } \bar{\delta} \text{ aux les mots } \text{tg } \forall p \in \mathcal{P}, \forall a \in \Sigma, \forall w \in \Sigma^*, \left. \begin{array}{l} \bar{\delta}(p, a) = \delta(p, a) \\ \bar{\delta}(p, aw) = \bar{\delta}(\delta(p, a), w) \end{array} \right\}$$

on s'autorise à écrire δ à la place de $\bar{\delta}$

• On montre que $\forall p \in \mathcal{P}, \forall w \in \Sigma^*, \delta(p, w) =$ plus long suffixe de pw qui est préfixe de m

$$= \sigma_m(pw)$$

Soit $p_1 \dots p_k$ (k peut être 0)

Soit $p \in \mathcal{P}$. Montrons / ne au $n = |w| \in \mathbb{N}^*$, $H_n: " \forall w \in \Sigma^*$ de taille $n, \delta(p, w) = \sigma_m(pw) "$

H_1 est OK par def de δ

Soit $n \geq 1$ tg H_n et $w \in \Sigma^*$ de taille $n+1$. En particulier $\exists a \in \Sigma, \tilde{w} \in \Sigma^*, w = a\tilde{w}$

$$\begin{aligned} \text{on a } \delta(p, w) &= \delta(p, a\tilde{w}) = \delta(\delta(p, a), \tilde{w}) \quad / \text{def} \\ &= \delta(\sigma_m(pa), \tilde{w}) \\ &= \sigma_m(\sigma_m(pa)\tilde{w}) \quad \text{par HR (car } |\tilde{w}| = n) \\ &\stackrel{\text{à montrer}}{\downarrow} = \sigma_m(pa\tilde{w}) = \sigma_m(pw) \end{aligned}$$

Il suffit pour conclure de mg $\sigma_m(\sigma_m(pa)\tilde{w}) = \sigma_m(pa\tilde{w})$

Deux cas se présentent: \rightarrow Si $\sigma_m(pa) \neq \epsilon$ alors $\exists i \in [1, k]$ tq $p_i \dots p_k a = \sigma_m(pa)$

En particulier, $\forall j < i$, $p_j \dots p_k a$ n'est PAS préfixe de m
(car m n'a pas de préfixe avec a qui est préfixe)

On a donc bien $\sigma_m(\sigma_m(pa)\tilde{w})$

$$= \sigma_m(p_i \dots p_k a \tilde{w}) = \sigma_m(pa\tilde{w})$$

(rien ne sert de chercher $\sigma_m(pa\tilde{w})$ plus à gauche que p_i car ces mots se partagent par m)

$$\rightarrow \text{Si } \sigma_m(pa) = \epsilon \text{ alors } \sigma_m(\sigma_m(pa)\tilde{w}) = \sigma_m(\tilde{w})$$

À nouveau, comme aucun suffixe de pa n'est préfixe de m (*), rien ne sert de chercher $\sigma_m(pa\tilde{w})$ à gauche de \tilde{w} donc $\sigma_m(pa\tilde{w}) = \sigma_m(\tilde{w})$ aussi

Cela conclut la réc

• Montrons que $\lambda(A_m) = \Sigma^* m$ par double inclusion.

$$\subset \text{ Si } w \in \lambda(A_m) \text{ alors } \begin{cases} \delta(\epsilon, w) = m & / \text{ def d' } \tilde{e} \text{ reconnu} \\ \sigma_m(w) & / \text{ point précédent.} \end{cases}$$

Donc m est suffixe de w donc $w \in \Sigma^* m$

$$\supset \text{ Si } w \in \Sigma^* m, \begin{cases} \sigma_m(w) = m & / \text{ def } \sigma_m \\ \delta(\epsilon, w) & / \text{ pt } \uparrow \text{ donc } w \in \lambda(A_m) \end{cases}$$

• Montrons que A_m est minimal pour $\Sigma^* m = L$.

définir + propre. $\begin{cases} p \rightarrow p^{-1}L \\ p \rightarrow p^{-1}L \end{cases}$ est injective
car si $p = m_1 \dots m_k \neq p' = m_1' \dots m_{k'}'$ ($k < k'$),
 $m_{k+1} \dots m_k \in p^{-1}L$ et $\notin p'^{-1}L$ car l'app. point. de $|P| \leq mb$

A_m est complet, dit et reconnaît $\Sigma^* m$: il suffit de mg il a le bon mb d'états car

que $|P| = mb$ de résiduels de $\Sigma^* m$. Notons $m = m_1 \dots m_p$. Soit $u \in \Sigma^*$ et calculons $u^{-1}L$

En fait la valeur de $u^{-1}L$ ne dépend que de $\sigma_m(u)$ DS tous les cas $u^{-1}L = \emptyset$ mots reconnus à partir de l'état $\sigma_m(u)$ dans A_m ?

Si $\sigma_m(u) = \epsilon$, $u^{-1}L = \Sigma^* m$ et $\forall k \in [2, p]$, si $\sigma_m(u) = m_1 \dots m_k$, $u^{-1}L = \bigcup_{k+1 \leq i \leq p} m_{k+1} \dots m_i m_{i+1} \dots m_p$
(aucun suffixe de u préfixe de m)

Ces résiduels sont $2^p - 1$: ce sont donc les résiduels de $L = \bigcup_{k=1}^p m_1 \dots m_k m_{k+1} \dots m_p$ mots reconnus à partir de l'état $m_1 \dots m_k$ de A_m

On en déduit que $\{\text{résiduels de } L\} = mb$ de préfixes de $m = |P|$

Donc A_m est minimal

et $2^p - 1$ car m reconnu de ϵ
 $m_1 \dots m_k$ rés de $m_1, m_2 \dots m_k$ rés de m_1, m_2
(mais rés de 3 autres) $\emptyset \neq$ car de longueur \neq

(19) Une fois l'automate construit, en passant t de A_m , on a algo en $O(|t|)$ pour la

recherche de m ds t . Δ toutefois on ne prend pas ici en compte le temps de calcul

de l'automate A_m (= le calcul de ses transitions) mais y a algo qui le fait en $O(|\Sigma| |m|)$