

TD 1 – Recherche de chaînes de caractères et expressions rationnelles

Margot Catinaud margot.catinaud@lmf.cnrs.fr
 Valentin Dardilhac valentin.dardilhac87@gmail.com

On considère dans tout ce TD un alphabet fini Σ .

I Recherche d'expressions rationnelles

Le but de cette partie est de concevoir un algorithme permettant de trouver toutes les occurrences d'une expression rationnelle e dans les préfixes d'un texte $T \in \Sigma^*$ en un temps $\Theta(|e| \cdot |T|)$. On commence par construire un automate *normalisé* reconnaissant e .

Définition 1: Automate normalisé

Un automate est dit normalisé s'il vérifie les conditions suivantes :

1. Il existe un seul état initial, un seul état final, et ces deux états sont distincts ;
2. Aucune transition ne va vers l'état initial ni ne sort de l'état final ;
3. Tout état autre que l'état final est la source soit d'exactly une flèche étiquetée par une lettre, soit d'au plus deux flèches étiquetées par le mot vide ε .

Définition 2: Taille d'une expression rationnelle

La taille $|e|$ d'une expression rationnelle e est son nombre de symboles. Plus précisément, on a :

$$|\varepsilon| = |a| \stackrel{\text{def}}{=} 1 \text{ pour } a \in \Sigma \quad |e + f| = |e \cdot f| \stackrel{\text{def}}{=} 1 + |e| + |f| \quad |e^*| = 1 + |e|.$$

Question 1 Montrer que pour toute expression rationnelle e , il existe un automate normalisé reconnaissant le langage $\mathcal{L}(e)$ et dont le nombre d'états est au plus $2 \cdot |e|$.

On cherche maintenant à calculer l'ensemble des états atteignables à partir de l'état initial en lisant un texte T de manière efficace, c'est-à-dire sans construire explicitement l'automate déterministe correspondant. Soit N la taille de l'automate obtenu à l'étape précédente.

Question 2 Donner un algorithme $\text{Trans}(P, a)$ qui, étant donnés un ensemble d'états P et une lettre a renvoie l'ensemble des états successeur de P par a (sans utiliser d' ε -transitions). Cet algorithme devra s'exécuter en temps $\Theta(N)$.

Question 3 Donner un algorithme $\text{Epsilon}(P)$ qui calcule en temps également $\Theta(N)$ l'ensemble des états atteignables par 0 ou plusieurs ε -transitions à partir de l'ensemble d'états P .

Question 4 En déduire un algorithme en temps $\Theta(|e| \cdot |P|)$ qui renvoie les préfixes de T qui appartiennent à $\mathcal{L}(e)$.

II Automate des parties

On considère ici $P \in \Sigma^*$ un motif de longueur m et on s'intéresse au langage \mathcal{L} des mots ayant P pour suffixe.

Question 5 Montrer que \mathcal{L} est rationnel en exhibant un automate non-déterministe \mathcal{A} à $m + 1$ états $\mathcal{Q} \stackrel{\text{def}}{=} \llbracket 0; m \rrbracket$ vérifiant :

$$\mathcal{L}(0) = \mathcal{L} \quad \text{et} \quad \forall k \in \llbracket 1; m \rrbracket, \mathcal{L}(k) = \{P[k+1 : m]\},$$

où $\mathcal{L}(i)$ est le langage accepté par \mathcal{A} en prenant l'état $i \in \mathcal{Q}$ comme état initial.

On définit maintenant la fonction $\pi^* : \llbracket 0; m \rrbracket \longrightarrow \mathcal{P}(\llbracket 0; m \rrbracket)$ de la façon suivante :

$$\pi^*(0) \stackrel{\text{def}}{=} \{0\} \quad \text{et} \quad \forall k \in \llbracket 1; m \rrbracket, \pi^*(k) \stackrel{\text{def}}{=} \{k\} \cup \pi^*(\pi(k)),$$

où $\pi(k) \stackrel{\text{def}}{=} \max\{k' < k \mid P[1 : k'] \sqsupset P[1 : k]\}$ (Rappel : $w \sqsupset x$ denote w est suffixe de x .)

Question 6 Montrer que, pour tout $k \in \llbracket 0; m \rrbracket$, $\pi^*(k) = \{k' \leq k \mid P[1 : k'] \sqsupset P[1 : k]\}$.

Question 7 Soit \mathcal{A}' l'automate des parties issu de \mathcal{A} . Montrer que l'ensemble \mathcal{Q}' des états atteignables dans \mathcal{A}' est exactement :

$$\mathcal{Q}' \stackrel{\text{def}}{=} \{\pi^*(k) \mid k \in \llbracket 0; m \rrbracket\}.$$

III Période d'un mot

Définition 3: Période

On dit que $p \in \llbracket 1; |u| \rrbracket$ est une *période* d'un mot $u \in \Sigma^*$ lorsque, pour tout $i \in \llbracket 1; |u| - p \rrbracket$, $u[i] = u[i+p]$.
On note $\text{Period}(u)$ la plus petite période de u .

On remarque que $\text{Period}(u)$ existe toujours puisque $|u|$ est considérée par définition comme une période de u .

Question 8 On considère la fonction π associée au mot u . Montrer que l'on a $\text{Period}(u) = |u| - \pi(|u|)$.

Question 9 Soient $p, q \in \llbracket 1; |u| \rrbracket$ deux périodes d'un mot $u \in \Sigma^*$ telles que $p+q \leq |u|$. Montrer que $\text{pgcd}(p, q)$ est aussi une période de u .

Pour tout mot $w \in \Sigma^*$, on note $w[: -2]$ le mot $w[1 : |w| - 2]$ obtenu en tronquant w de ses deux derniers caractères. Soit $(F_n)_{n \in \mathbb{N}}$ la suite des mots de Fibonacci définie par :

$$\forall n \in \mathbb{N}, F_n \stackrel{\text{def}}{=} \begin{cases} \varepsilon & \text{si } n = 0, \\ b \in \Sigma & \text{si } n = 1, \\ a \in \Sigma & \text{si } n = 2, \\ F_{n-1} \cdot F_{n-2} & \text{sinon.} \end{cases}$$

Question 10 1. Calculer $\text{pgcd}(|F_n|, |F_{n+1}|)$ pour tout entier $n \in \mathbb{N}$.

2. Montrer que $F_n[: -2]$ est préfixe de F_{n-1}^2 et de F_{n-2}^3 pour tout $n \in \mathbb{N}$, $n \geq 5$.

3. En déduire que $|F_{n-1}|$ et $|F_{n-2}|$ sont des périodes de $F_n[: -2]$. Leur PGCD est-il également une période ?

Devoir maison 1 Proposer un algorithme en temps linéaire pour trouver le plus grand entier $n \in \mathbb{N}$ tel que, étant donné un texte $T \in \Sigma^*$, il existe un mot $u \in \Sigma^*$ tel que $T = u^n$. Démontrer sa correction.