

(I) Formalisme syntaxique

1.1) Définition - Langage rationnel

- Définition 1 (Alphabet, mot, langage) [CAR], p 13
- Un alphabet Σ est un ensemble fini dont les éléments sont appelés lettres ou symboles
 - Un mot est une suite finie d'éléments de Σ . Le mot vide est noté ϵ . Σ^* est l'ensemble des mots, appelé monoïde libre sur Σ
 - Un langage L est une partie de Σ^*

Exemple: Mots dont la longueur est un nombre premier.

Définition 2. (Opérations rationnelles) [CAR], p 15

Les opérations rationnelles sur les langages sont :

- L'union de deux langages rationnels L et L' est noté $L + L'$.
- Le produit de deux langages rationnels L et L' est $LL' = \{uv | u \in L, v \in L'\}$
- Soit $L \subseteq A^*$. on définit l'étoile de L par :
 $L^0 = \{\epsilon\}, L^{i+1} = LL^i, L^* = \bigcup_{i \geq 0} L^i$

Définition 3. (Langages rationnels) [CAR], p 33

La classe R des langages rationnels sur Σ est la plus petite famille de langages tels que

- (i) $\{\epsilon\} \in R$ et $\{a\} \in R$ pour tout $a \in \Sigma$

- (ii) R est close par les opérations rationnelles

Exemples: $\{\epsilon\} = \emptyset^*, \Sigma^* \in R$

1.2) Expressions régulières

Définition 4. (Expression régulière.) [Evol], p 10

La classe Σ des expressions rationnelles sur Σ est la plus petite famille d'expressions telles que

- (i) $\emptyset \in \Sigma$ et $a \in \Sigma$ pour tout $a \in \Sigma$

- (ii) si $(E, E') \in \Sigma^2$, alors $((E+E'), (EE'), E^*) \in \Sigma^2$

Remarque: Par abus de notation, si il n'y a pas ambiguïté, on omettra les parenthèses, et si $A = \{a_1, \dots, a_n\}$, on notera A pour $a_1 + \dots + a_n$.

Exemples: $(a+b^*)$ noté ab^* , $(ab)^*a, A^*, a^*, (a+a)$ sont des expressions rationnelles

Propriété 5 Les expressions rationnelles sont non ambiguës.
On peut donc décrire des fonctions induites sur les expressions rationnelles

Définition 6 Le langage $L(E)$ associé à une expression rationnelle est défini par :

- (1) $L(\emptyset) = \emptyset, L(\epsilon) = \{\epsilon\}, L(a) = \{a\}$ pour tout $a \in \Sigma$
- (2) $L((E_1 + E_2)) = L(E_1) + L(E_2)$
- (3) $L((E_1 E_2)) = L(E_1) L(E_2)$
- (4) $L(E^*) = L(E)^*$

Propriété 7 L'application $L: \Sigma \rightarrow R$ est surjective.
 $\epsilon \mapsto L(\epsilon)$

Contre exemple pour l'injectivité: $L((a+a))^* = L(a^*)$

1.3) Équation sur les langages

[CAR], 40

On sera amenés à résoudre des équations linéaires sur les langages. Pour cela, on introduit des outils

Lemma 8: Lemme d'Arden

Soient U, L deux langages et l'équation $X = UX + L$,
X désignant un langage

- 1) Si $\epsilon \notin U$, l'unique solution est $X = U^*L$

- 2) Si $\epsilon \in U$, les solutions sont de la forme $X = U^*(L+Y), Y \subseteq A^*$

Élimination de Gauss

Pour résoudre un système d'équations $\{X_p = \sum_{q \neq p} AX_q + Y, p \in Q\}$

on procède par élimination successive des langages X_p en utilisant le lemme d'Arden.

II

Automates finis

2.1) Définition des automates

Définition 9 (Automate fini)

Un automate fini est un quintuplet $A = (Q, \Sigma, \delta, I, F)$

où Q est fini, $I \subseteq Q$, $F \subseteq Q$, $\delta \subseteq Q \times \Sigma \times Q$.

Les éléments de Q sont les états, ceux de I sont les états initiaux, ceux de F les états finaux, ceux de δ les transitions.

Définition 10 (Chemin, chemin acceptant, mot accepté, Langage accepté)

- Un chemin est une suite finie $q_0 \xrightarrow{a_1} q_1 \dots \xrightarrow{a_n} q_n$ telle que $\forall i \in [1, n], (q_{i-1}, a_i, q_i) \in \delta$. On note $q_0 \xrightarrow{a_1 \dots a_n} q_n$
- Un chemin est acceptant si $q_0 \in I$, $q_n \in F$
- Un mot est accepté par A si il est l'étiquette d'un chemin acceptant.
- Le langage accepté par A est l'ensemble des mots acceptés par A .
- Un langage est reconnaissable s'il existe un état qui l'accepte.

Exemple : (cf Annexe) : recherche de mot dans un texte : abaa

Définition 11 (Automate émorcé) Un automate est émorcé si pour tout état passe au moins un chemin acceptant.

Exemple : cf Annexe

Définition 12 (Automate normalisé) A est normalisé si $I = \{i\}$, $F = \{f\}$ et $\forall a \in \Sigma, q \in Q, (q, a, i) \notin \delta$ et $(f, a, q) \notin \delta$

Propriété 13 Pour tout automate A , l'automate normalisé A' accepte le même langage. (A et A' sont équivalents)

Exemple : cf Annexe

Définition 14 (Automate déterministe) A est déterministe si $I = \{i\}$ et $(p, a, q) \in \delta, (p, a, q') \in \delta \Rightarrow q = q'$

Exemple : cf Annexe

[CTR], p 35-36

2.2) Les langages reconnaissables sont rationnels

Définition 15 (Grammaire linéaire à gauche) [CAR], p 75

- Une grammaire linéaire à gauche est un quadruplet (Σ, V, P, S) où Σ et V sont des alphabets finis et disjoints, appelés terminaux et variables, et P est une partie finie de $V^*(\Sigma V V^* \{E\})$ appelée règles. $S \in V$ est le symbole de départ.

- (Déivation) v se dérive en v' si il existe $a \in \Sigma^*$, $x \in V$ et $w \in \Sigma V v \{E\}$ tels que $v = ax, v' = aw, (x, w) \in P$.

On note $v \rightarrow v'$.

On note $v \rightarrow^* v'$ s'il existe une suite finie de dérivations partant de v à v' .

-(Langage engendré) $L_g = \{v \in \Sigma^* | (Vv \{E\}), S \rightarrow^* v\}$

$$L_g = L_g \cap \Sigma^*$$

Définition 16 Sat $A = (Q, \Sigma, \delta, I, F)$ [SAW], p 107

$$P \subseteq Q, L_p = \{f \in \Sigma^* | \exists t \in T, p \xrightarrow[A]{f} t\}$$

On a $L_p = \bigcup_{(q, f, t) \in P} L_q + \delta_{P, F}$, $\delta_{P, F} = E$ si $P \subseteq F$, \emptyset sinon

$$\text{et } L(A) = \bigcup_{p \in P} L_p$$

Proposition 17 Les langages reconnaissables sont engendrés par une grammaire linéaire à gauche, et sont rationnels

2.3) Les langages rationnels sont reconnaissables

Lemma 18 Un langage L est reconnaissable si et seulement si $L \setminus \{E\}$ est reconnaissable

On peut construire par induction un automate normalisé reconnaissant $L \setminus \{E\}$ écrit par une expression rationnelle (cf Annexe)

théorème de Kleene: Les langages rationnels et les langages reconnaissables sont les mêmes

III Application du théorème de Kleene

Le théorème de Kleene donne des conditions de rationalité des langages.

3.1) Lemme de l'étoile

[SAK], p78

Lemme 19 (Lemme de l'étoile)

Si L est rationnel, $\exists N \in \mathbb{N}$ tel que pour tout $f \in L$, si $f = g_1 h g_2$ et $|h| \geq N$, alors il existe une factorisation $h = uvw$, $v \neq \epsilon$ et $g_1 u v^* w g_2 \subset L$.

Contre exemple: Ce lemme ne donne pas une CNS : [SAK], p80

$$L = \{(aab)^n (abb)^m | n \in \mathbb{N}\} \cup A^*(aaa + bbb) A^*$$

Lemme 20 (Lemme de l'étoile par blocs)

Si L est rationnel, $\exists N \in \mathbb{N}$ tel que pour tout $f \in L$, pour toute factorisation $f = v_1 v_2 \dots v_N w$, $|v_i| \geq 1$, alors il existe $0 \leq j < k \in \mathbb{N}$ tel que

$$v_1 \dots v_j (v_{j+1} \dots v_k)^* v_{k+1} \dots v_N w \subset L$$

Contre exemple: Ce lemme ne donne pas une CNS

par contre $L = \{a^{k_1} b a^{k_2} b \dots a^{k_n} b, \exists i, i \neq k_i\}$

3.2) Quotients à gauche et minimisation

Définition 21 (Quotient à gauche)

[CAR], 45, 46

$L \subset A^*$, le quotient à gauche de L par $v \in A^*$ est $v^{-1}L = \{vvt^*, vuv\}^*$

Proposition 22: Un langage est rationnel si et seulement si il a un nombre fini de quotients à gauche

Définition 23 (Automate minimal)

Soit L un langage rationnel. L'automate minimal de L est $A_L = (\mathcal{Q}, \Sigma, E, \{\iota\}, F)$, où $\iota \in \cup_{L \subset A^*} \{v \in L, v \in \Sigma^*\}$ et $E = \{v^{-1}L - \{v\}^*, v \in \Sigma^*\}$. $F = \{\iota^{-1}L, \iota \in L\}$

$$\cdot E = \{v^{-1}L - \{v\}^*, v \in \Sigma^*\}, F = \{\iota^{-1}L, \iota \in L\}$$

Définition 24 Congruence de Nerode

$\Delta = (\mathcal{Q}, \Sigma, \delta, \{\iota\}, F)$ un automate déterministe complet. Δ est une congruence si $q \Delta q' \iff (\forall w \in \Sigma^*, (qw \in F \iff q'w \in F))$

Propriété 25: Si A reconnaît L , l'automate minimal de L est égal à $A/\Delta = (\mathcal{Q}/\Delta, \Sigma, \delta', \{\iota/\Delta\}, \{F/\Delta\})$. $\delta' = \{[q] \xrightarrow{a} [q.a], q \in \mathcal{Q}, a \in \Sigma\}$.

IV Applications des langages rationnels

4.1) Recherche de mots dans un texte [BBC]

Algorithmes de Knuth-Morris-Pratt (DVP)

4.2) Problème de séparation par Automate [FB]

Le problème de séparation par automates est NP-complet (DVP)

Références

[CAR] Olivier Carton, Langages formels.

[WOL] Pierre Wolper, Introduction à la calculabilité

[SAK] Jacques Sakarovitch, Éléments de théorie des automates


[BBC] Beauquier, Boistel, Chéchine, Éléments d'algorithmique..

[FB] Floyd, Beigel, The language of machines.


[HU] Hopcroft Ullmann, Introduction to automata theory.

Annexe


recherche de mot : abaa




automate émondé



automate normalisé



émondé



théorème de Kleen.

$$A = \rightarrow \textcircled{1} \xrightarrow{a} \textcircled{2} \rightarrow \quad L(A) = \{a\}$$

$$A_\emptyset = \rightarrow \textcircled{1} \quad \textcircled{2} \rightarrow \quad L(A_\emptyset) = \emptyset$$

$$A_1 = \rightarrow \textcircled{1} \rightarrow \boxed{A_1} \rightarrow \textcircled{2} \rightarrow \quad L_1 = L(A_1), \epsilon \notin L_1$$

$$A_2 = \rightarrow \textcircled{1} \rightarrow \boxed{A_2} \rightarrow \textcircled{2} \rightarrow \quad L_2 = L(A_2), \epsilon \notin L_2$$

$$A_+ = \rightarrow \textcircled{1} \rightarrow \boxed{A_1} \rightarrow \textcircled{2} \rightarrow \quad L(A_+) = L_1 + L_2$$

$$A_\cdot = \rightarrow \textcircled{1} \rightarrow \boxed{A_1} \rightarrow \textcircled{2} \rightarrow \boxed{A_2} \rightarrow \textcircled{3} \rightarrow \quad L(A_\cdot) = L_1 L_2$$

$$A^* = \rightarrow \textcircled{1} \rightarrow \boxed{A_1} \rightarrow \textcircled{2} \rightarrow \quad L(A^*) = L_1^* \setminus \{\epsilon\}$$


↓

Algorithm de Thompson.

Autre possibilité (Egushakov).

(très courant.)

$$\frac{(a+b)^*}{1} + \frac{c}{2} + \frac{d}{3} + \frac{c}{4} + \frac{d}{5} + \frac{a}{6}$$



Le problème de séparation par automates est NP-complexe.

Énoncé du problème :

Soit $(S, T) \in \Sigma^* \times \Sigma^*$ deux ensembles finis et disjoints et soit λ un automate déterministe à n états, $\lambda = (Q, \Sigma, \delta, \{q_0\}, F)$.
On cherche un automate déterministe à n états, $T = (Q, \Sigma, \delta, \{q_0\}, F)$, tel que $S \subseteq L(\lambda)$ et $T \cap L(\lambda) = \emptyset$.

Théorème : Ce problème est NP-complet.

Preuve :

• Ce problème est NP : étant donné un automate λ déterministe construit de manière non déterministe, on vérifie en temps linéaire que $S \subseteq L(\lambda)$, et $T \cap L(\lambda) = \emptyset$.

• Ce problème est NP-dur : On va réduire polynomiallement le problème SAT au problème de séparation par automates ; on construit les ensembles S et T .


Soit $T = \bigwedge_{i=0}^{m-1} C_i$ une CNF sur les littéraux x_0, \dots, x_{n-1} , on choisit $|V| = m + 2n$ et l'alphabet $\Sigma = \{\alpha, \beta\}$.

On note $b_0, \dots, b_{n-1} = x_0, \dots, x_{n-1}, \bar{x}_0, \dots, \bar{x}_{n-1}$.

Soit $S_0 = \{\varepsilon, \alpha^n\}$,

$T_0 = \{\alpha^k, \alpha^{ck}\}$

Si λ accepte S_0 et refuse T_0 , on a le résultat, alors il suffit d'ajouter une boucle de transition étiquetée par α , avec $F = \{f\}$:
On note $C = \bar{C}$ et $Q = \{s_0, \dots, s_{n-1}, b_0, \dots, b_{n-1}\}$ dans l'ordre des transitions.



Utiliser le codage suivant par des fractions échiquetées par b :

- $C_i \xrightarrow{b} l_j \Rightarrow l_j$ est un littoral de C_i
- $l_j \xrightarrow{b} C \Rightarrow l_j$ est un littoral vrai.
- On voit même : $l_j \xrightarrow{b} q, q \in Q \Rightarrow q = c$ et l_j est vrai.

$$T_1 = \{a^i b a^r, i \leq m, r \leq k\} \setminus \{a^i b a^{2r-5}, l_j \text{ littoral de } C_i\}$$

$$T_2 = \{a^{m+j} b a^i, j \leq 2r, 0 \leq i \leq k\}$$

- Il faut éviter les cas où x_i et \bar{x}_i sont codés vrais

$$T_3 = \{a^{m+j} b a^{m+r+j} b, j < r\}$$

Finalement, pour résoudre le problème SAT, il faut que chaque classe C_i soit un littoral vrai :

$$S_4 = \{a^i b b, i \leq m\}$$

$$S = S_0 \cup S_1 \text{ et } T = T_0 \cup T_1 \cup T_2 \cup T_3.$$

On algorithmique qui résout le problème de séparation de SET avec k États donne une solution de SAT. Il ne peut donc être polynomial \square

Recherche de motifs : algorithme de Knuth, Morris et Pratt

Recherche de motifs :

C'est un problème utile notamment en traitement de texte et en biologie (recherche d'une séquence d'acides aminés via un brin d'ADN). On veut déterminer efficacement, étant donné un mot $x \in \Sigma^*$, l'appartenance à $\Sigma^* x \Sigma^*$ d'un mot t , et trouver, le cas échéant, la première occurrence de x dans t .

Un algorithme naïf :

Soit $m = |x|$ et $n = |t|$. On pourrait penser à comparer à x tous les sous-mots de t de longueur m successivement, et s'arrêter en cas d'égalité.

On obtiendrait :

RECHERCHE(x, t):

$m = |x| ; k = 0 ; trouv = \text{faux} ; posx = \text{faux} ; j = m + 1$
tant que (non trouvé) et (non trouv)
 si $t_{k+m} = x_m$ alors trouv = vrai
 si $t_k = x_0 + \dots + x_{m-1}$ alors trouv = vrai
 sinon $k = k + 1$ fin

fin

si trouvé = vrai alors
 sinon retrouve ()
fin

On effectue donc $O(m \times n - m + 1)$ comparaisons, c'est le cas pour $x = a - ab$; $t = a - ab$

Les trois sont redondantes; par exemple, si $x = a - ab$ et que le test échoue au rang k après avoir testé avec succès $t_{k+1} = x_0$ et $t_{k+2} = x_1$, il est inutile de relancer un test au rang $k+1$ puisque $x_2 \neq x_1$, i.e. $t_{k+2} \neq x_2$.

Algorithm de Morris et Pratt

Si un préfixe, à l'échec se produit lors de la comparaison de $x_i \sim t_{\#i}$, on a
 $x_1 \dots x_{i-1} = t_{\#1} \dots t_{\#i-1}$ et $x_i \neq t_{\#i}$, donc $t_{\#1} \dots t_{\#i-1}$ est préfixe
de x .

Si une recherche est lancée à un rang $\ell \in [\alpha + 1; \beta - 1]$, alors tout $t_{\#1} \dots t_{\#\ell-1}$
est un préfixe de $t_{\#1} \dots t_{\#\ell-1} \dots t_{\#i-1} = x_1 \dots x_{i-1}$. On compare donc x à son
rang - mot de x , comparaison que l'on peut effectuer indépendamment de t
et garder en mémoire.

Pour formaliser cette idée, on introduit la notion de bord : un bord de $x \in \Sigma^*$
est un sous-mot strict de x qui consiste à la fois préfixe et suffixe.

On note $\text{Bord}(x)$ le bord maximal de x .

On définit la fonction $\beta : \mathbb{II}^0, m \rightarrow [\ell-1; n-1]$ (où $m \leq n$)
par $\beta(0) = -1$ et $\forall i \in \mathbb{II}^1, m \rightarrow \beta(i) = |\text{Bord}(x_1 \dots x_i)|$

On a toujours $\beta(i) \leq i$

Revenons à notre recherche de motif : si $x_1 \dots x_{i-1} = t_{\#1} \dots t_{\#\ell-1}$
et $x_i \neq t_{\#i}$, dans $P \in [\alpha + 1; \beta - 1]$, alors $t_{\#1} \dots t_{\#\ell-1} \dots t_{\#i-1}$ ne
peut être un préfixe de x (ordre sur recherche empêche de perdre une
chance de succès) que s'il est un bord de $x_1 \dots x_{i-1}$

On va donc vouloir relancer une comparaison à partir du rang ℓ
tel que $t_{\#1} \dots t_{\#\ell-1} \dots t_{\#i-1} \dots t_{\#i+1} = t_{\#1} \dots t_{\#\ell-1}$

i.e. $\ell = \alpha + m - \beta(\ell-1)$
Considérons, lors d'un calcul, un cas d'échec au rang ℓ et à la
lettre x_i ($x_1 \dots x_{i-1} = t_{\#1} \dots t_{\#\ell-1} \dots t_{\#i-1} \neq t_{\#1} \dots t_{\#\ell-1}$), il suffit donc
de "continuer" la comparaison en remplaçant x_i par $\beta(i) = \alpha + \beta(\ell-1)$

On appelle δ fonction de suppression de x

Dans l'algorithme de Morris et Pratt, δ y représentent
les lettres communes dans x et t respectivement. On a donc pour
succès de lancé $x_1 \dots x_m = t_{\#1} \dots t_{\#\ell-1} \dots t_{\#g-1}$

RECHERCHE MP(x, t):

```
i := 1; j := 1  
tant que ( $i \leq m$ ) et ( $j \leq n$ ) faire  
  si  $t_i \geq 1$  et ( $t_i \cdot [i:j] \neq x \cdot [i:j]$ ) alors  $i := i + 1$   
  sinon  $i := i + 1$ ;  $j := j + 1$  faire
```

fin

$i \geq m$ alors retourne $j - m$ sinon retourne 0 fin

L'algorithme effectue au plus $2m - 1$ comparaisons si on a déjà calculé la fonction s . En effet, une comparaison réussie révèle sûrement strictement y_j , et un échec sûrement strictement y_{j+1} .

Le calcul de s est polynomial en m (en général en α^m)

Algorithm de Knuth, Morris et Pratt

Il existe encore un type de comparaisons redondantes qu'on peut facilement éliminer : si $x_i = x_{i+1} = \dots = x_{i+p(i)-1}$, alors il est inutile, dans le cas où $x_1 \dots x_{i-1} = x_{i+1} \dots x_{i+p(i)-1}$ et $x_{i+1} \neq x_i$, de relancer un test sur rang $p = i - 1 - p(x_{i+1})$, comme le fait l'algorithme de Morris et Pratt : ce test va nécessairement échouer puisque $x_{i+1} = x_{i+1-p(x_{i+1})}$ est distinct de x_i , donc de $x_{i+p(i)-1}$.

On adapte donc cette fonction d'appelance, pour interdire le cas $x_{i+1} = x_i$:

Plus formellement, on dira que deux préfixes v et w de x sont disjoints si l'un est de la forme $x_{i+1}x_{i+2} \dots x_{i+p(i)}$ et w n'est pas préfixe de x , ou est appelé bord disjoint de v si v n'est pas bord de v et tous sont des préfixes disjoints. On note $DBord(v)$ le plus long bord disjoint de v , s'il existe.

Les bord "intérieurs" au sens de la recherche de motif sont les bord disjoint. Les autres ne viennent nulle part à cause du problème énoncé en début de partie.

On définit donc $\gamma : \mathbb{I}_{[0,m]} \rightarrow \mathbb{I}_{[-1,n-1]}$

$i \mapsto 1$	$i \mapsto 1$
$i \mapsto 1$	$i \mapsto 1$
$i \mapsto 1$	$i \mapsto 1$

On définit donc $\chi : \mathbb{I}_{[0,m]} \rightarrow \{DBord(x_1 \dots x_i)\mid x_1 \dots x_i \text{ a un bord disjoint de } x\}$

En décomme une nouvelle fonction de suppression :
 $n(i) = 1 + \gamma(i-1)$

L'algorithme est alors le même en remplaçant γ par n et tant que $i < m$ et $j < n$

Fonctions de suppression

On utilise le lien entre β et γ :

$$\begin{aligned} \beta(1+j) &= 1 + \gamma^2(\beta(j)) \text{ où } \beta \text{ est le plus petit entier } l \text{ tel que :} \\ (1+\gamma^2(\beta(j))) &= 0 \text{ ou } (1+\gamma^2(\beta(j))) = 1 \text{ fin} \end{aligned}$$

$$\gamma(j) = \begin{cases} \beta(j) & \text{si } j = m \text{ ou } \alpha < j \leq n \\ \gamma(\beta(j)) & \text{sinon} \end{cases}$$

On va décrire un algorithme calculant n :

```
SUPPLEMENT( $x$ );  

 $n[1]:=0$ ;  $i:=0$   

pour  $j = 1$  à  $m-1$  faire  

  tant que  $i > 0$  et  $x[i] \neq x[i+1]$  faire  $i := n[i]$   

     $i := i+1$   

  si  $x[i+1] \neq x[i]$  alors  $n[1+j]:=i$ , sinon  $n[1+j]:=n[i]$   

fin
```

C'est la traduction de la deuxième propriété ci-dessus : La boucle tant que continue tant que $n[j] = 1 + \beta(j-1)$

Le calcul est linéaire en $m = 161$.

En termes d'automates, cette procédure revient à implementer l'automate minimal de $\overline{x^*x}$, i.e. un automate où tout état (les préfixes de x) dont les transitions sont : $i \xrightarrow{x_1} j$ lorsque x_1, \dots, x_j est le plus long préfixe de $x_1 \dots x_n$ qui est suffisante de x_1, \dots, x_j (on confond un préfixe et sa longueur en équivalant les états)
pour $x = abcabc$, il t =

