

## Langages rationnels. Exemples et applications.

90

[C] p.15

[C] p.15

[C] p.15

[C] p.15

[C] p.34

[C] p.126

[S] p.126

Les langages rationnels sont au premier niveau de la hiérarchie de Chomsky. Ils servent notamment dans les éditeurs de texte, avec la recherche de motifs.

### I - Langages rationnels et langages reconnaissables.

#### 1) Langages rationnels

Soit  $A$  un alphabet.

Déf 1: Un langage  $L$  sur  $A$  est un ensemble de mots sur  $A$ .

Déf 2: L'union est l'opération qui à deux langages  $L$  et  $L'$  associe le langage  $L \cup L' = \{u \mid u \in L \text{ ou } u \in L'\}$

Le produit est l'opération qui à  $L$  et  $L'$  associe le langage  $L \cdot L' = \{uv \mid u \in L, v \in L'\}$

Soit  $L$  un langage. On définit l'opération  $*$ :

$$L^0 = \{\epsilon\}, \quad \forall i \in \mathbb{N}, \quad L^{i+1} = L \cdot L^i, \quad L^* = \bigcup_{i \geq 0} L^i.$$

Ex 3: Soit  $L = \{u \in A^* \mid |u| \text{ est paire}\}$  où  $|u|$  = longueur de  $u$ .

Soit  $L' = \{u \in A^* \mid |u| \text{ est impaire}\}$ . Alors:

$$L + L' = A^*, \quad LL' = L'L = L'$$

Soit  $L = \{a^n b \mid n \geq 0\}$ .  $L^*$  est l'ensemble des mots qui se terminent par un  $b$ .

Déf 4: On définit la classe  $\mathcal{E}$  des expressions rationnelles par induction:

- $\emptyset \in \mathcal{E}$  et  $\forall a \in A, a \in \mathcal{E}$

Il faut parenthèse

$E, E' \in \mathcal{E}$ , les expressions  $E+E'$ ,  $E \cdot E'$  et  $E^* \in \mathcal{E}$ .

Rq: Cette définition inductive est non-ambiguë.

Déf 5: Sémantique. À toute expression rationnelle  $E$ , on associe le langage rationnel  $L(E)$  par induction:

- $L(\emptyset) = \emptyset ; \forall a \in A, L(a) = a$
- $\forall E, E' \in \mathcal{E}, L(E+E') = L(E) + L(E')$
- $L(E \cdot E') = L(E) \cdot L(E')$
- $L(E^*) = L(E)^*$

Déf 6: Deux expressions rationnelles  $E$  et  $E'$  sont équivalentes lorsqu'elles décrivent le même langage. On note:

Ex 7:  $L = A^* a A^*$  est l'ensemble des mots contenant au moins un  $a$ .

$$(0 + a(1+b \cdot 1))^* = (ab \cdot a)^*$$

Déf 8: Un langage est rationnel lorsque il est décrit par une expression rationnelle.

Prop 9: La classe  $R$  des langages rationnels est la plus petite classe de langage telle que:  $\emptyset \in R$ ;  $\forall a \in A, \{a\} \in R$ ; et  $R$  est close par union, produit et étoile.

#### 2) Langages reconnaissables

Déf 10: Un automate  $A$  sur l'alphabet  $A$  est un quintuplet  $(Q, A, \delta, I, F)$  où  $Q$  est un ensemble fini d'état;

$I \subseteq Q$  et  $F \subseteq Q$  sont respectivement les états initiaux et finaux.

$\delta: Q \times A \rightarrow Q$  est la fonction transition.

On note  $q \xrightarrow{a} q'$  lorsque  $q' \in \delta(q, a)$

Rq: On représente les automates par des graphes, avec des flèches entrantes et sortantes pour les états initiaux et finaux.



Déf 12: Un mot  $u = a_1 \dots a_n$  est reconnu par  $A = (Q, A, \delta, I, F)$  lorsque  $\exists q_0, \dots, q_n \in Q$  si  $q_0 \in I$ ,  $q_n \in F$  et  $q_0 \xrightarrow{a_1} q_1 \xrightarrow{a_2} \dots \xrightarrow{a_n} q_n$ . On note  $A \models u$  ou  $q_0 \xrightarrow{u} q_n$

Déf 13: Le langage  $L(A)$  reconnu par  $A$  est l'ensemble des mots  $u$  reconnus par  $A$ .

Ex 14: L'automate de l'exemple 11 reconnaît les mots ayant un nombre pair de  $a$ .

#### 3) Théorème de Kleene:

Prop 15: À toute expression rationnelle, on peut associer un automate fini reconnaissant le même langage  
↳ La construction de l'automate se fait par exemple par la construction de Thompson (cf. annexe).

[C]

p.34

[B]

p.309

[S]

p.26

[C]

p.33

[C]

p.35

[S]

p.94

[C]

p.37

[S]

p.98



### III - Applications :

[S] des langages rationnels ont de nombreuses applications, notamment liées à l'analyse lexicale des langages de programmation et à la recherche de motifs.

#### 1) Recherche de motif

[G] On considère un texte  $t = t_1 \dots t_k$ ; on cherche une occurrence du motif  $x = x_1 \dots x_m$  dans  $t$ .

##### a. Algorithmme naïf:

On compare le motif à chaque facteur de  $t$  de longueur  $m$ ; on s'arrête si on trouve une occurrence de  $x$ .

Complexité en pire cas:  $O(mk)$  lorsque  $n$  petit devant  $k$ .

##### b. Algorithmme de Knuth-Morris-Pratt et automate de Simon.

On optimise le décalage dans la comparaison des motifs en considérant le plus grand suffixe lu qui est aussi préfixe du motif  $x$ .

On peut également construire l'automate des occurrences et l'utiliser dans la recherche du motif

Complexité en pire cas:  $O(n+k)$

Rq: Cette recherche de motif est utilisée pour rechercher les différents lexèmes dans le cadre de l'analyse lexicale.

#### 2) Séparation par automates.

Sont  $L$  et  $K$  deux langages finis. Soit  $k \in \mathbb{N}$ .

Existe-t-il un automate déterministe à  $k$  états tel que  $L \subseteq L(A)$  et  $T \cap L(A) = \emptyset$ ?

Thm 34: Ce problème est NP-complet.

DPT

### Références

[C]: Carton: Langages formels

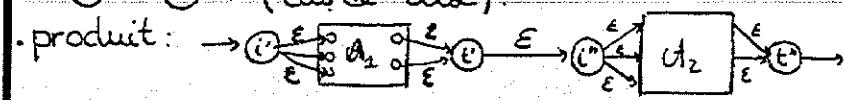
[S]: Sakarovitch: Éléments de théorie des automates

[B]: Beauquier, Berstel, Chrétienne: Éléments d'algorithmique

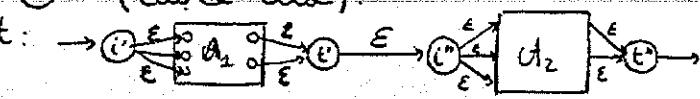
[FB]: Floyd-Beigel : Language of machines

Annexe1 : Construction de Thompson:

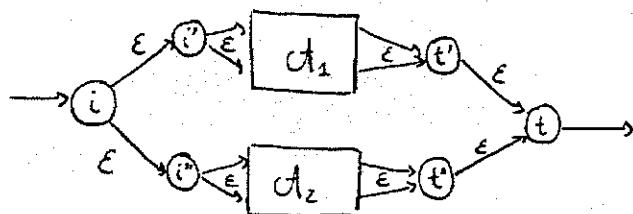
. $\rightarrow$   $\circ \xrightarrow{a} \circ$  (cas de base)



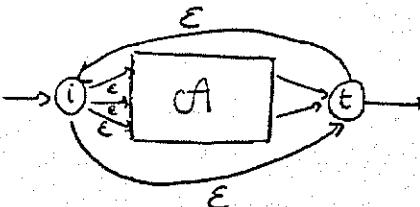
.produit:



.union:



.étoile:



## Recherche de motif

Entrée : Un texte  $t = t_1 \dots t_n$

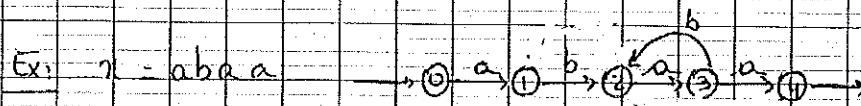
Un motif  $n = n_1 \dots n_m$

Sortie : des positions auxquelles apparaît le motif  $n$  dans  $t$ .  
(S'il n'apparaît pas, rien)

### I Algorithme de Simon

On construit l'automate du motif

dans lequel se trouve à l'état  $q$ , c'est qu'on a lu les  $q$  premières lettres du motif



On peut construire l'automate en plusieurs étapes :

Déf: Soit  $\sigma$  la fonction suffice définie par :

$$\sigma: A^* \rightarrow [0, m]$$

$$u \mapsto \sigma(u) = \max \{k: n_k \dots n_{n-k} = u\} \quad (n = n_1 \dots n_m \text{ est le motif})$$

( $\sigma$  correspond à la longueur du plus long suffixe de  $u$  qui est préfixe de  $n$ .

Rq:  $\sigma$  est suffisant de tout mot donc  $\sigma$  est bien défini

( $\{\sigma(n_k \dots n_n)\}_{1 \leq k \leq n}$  est non-vide avec la convention

$$n_0 \dots n_n = \epsilon \text{ lorsque } k=0$$

On définit l'automate du motif  $c$  :  $(Q, A, \delta, I, F)$  par

$$\bullet Q = [0, m], \quad I = \{\epsilon\}, \quad F = \{m\}$$

$$\bullet \forall q \in Q, \forall a \in A, \quad \delta(q, a) = \sigma(n_{n-q} \dots n_m, a)$$

(le plus grand préfixe de  $n$  qui soit suffixe de  $n_{n-q} \dots n_m$ )

Rq: Cet automate est déterministe complet

Algorithme:

Simon ( $t, n$ ):

$q \leftarrow 0$

pour  $i = 1$  à  $m$ :

$q \leftarrow S(q, t_i)$

si  $q = m$  alors imprimer "position  $i - m$ ".

L'algorithme termine (facile) et est correct (ça va marcher).

On peut montrer que la complexité est en  $O(n \cdot m^3 |A|)$ .

## II L'algorithme de Knuth-Morris-Pratt.

On veut améliorer l'algorithme précédent avec un prétraitement moins coûteux.

Pour cela, on va calculer une fonction préfixe  $\pi$  (qui dépendra du motif), qui exprimera les correspondances entre le motif et ses propres décalages.

Prefixe ( $n, \dots, n_m$ ):

$\pi(1) \leftarrow 0$

$k \leftarrow 0$

pour  $q = 2$  à  $m$ :

tant que  $k > 0$  et  $n_{k+1} \neq n_q$ ,

$k \leftarrow \pi(k)$

$x_1 \dots x_{k+1} = n_q$

$k \leftarrow k + 1$

$\pi(q) \leftarrow k$

retourner  $\pi$ .

KMP ( $n, \dots, n_m, t, \dots, t_m$ ):

$\pi \leftarrow \text{Prefixe}(n, \dots, n_m)$

$q \leftarrow 0$

pour  $i = 1$  à  $n$ :

tant que  $q > 0$  et  $t_{q+1} \neq n_i$ ,

$q \leftarrow \pi(q)$

si  $n_{q+1} = t_i$

$q \leftarrow q + 1$

si  $q = m$

imprimer "position  $i - m$ ".

Cet algorithme termine (ok) et est valide (long).

### Complexité:

On compte le nombre de comparaisons de lettres.

#### Dans KMP:

On compte le nombre de tests positif et négatif.

- Si le test est positif. On incrémente  $i$ .  
Si  $1 \leq i \leq n$  donc  $i$  au plus  $n$  tests
- Si le test est négatif,  $i$  inchangé mais  $q$  diminue strictement  
donc  $i - q$  augmente strictement à chaque test négatif  
(+ teste inchangé à chaque test positif)

clerc ( $i - q = 0$  au début)  
 $\#(\text{torts} < 0) \leq i - q$  (à la fin)  
 $i \leq n$

Donc la complexité est en  $O(n)$ .

#### Dans Préfixo:

idem : au plus  $m$  tests positif

•  $\#(\text{torts} < 0) \leq q = k$  (1 strict quand  $< 0$ ,  
quand  $> 0$ )  
 $< m$

la complexité est en  $O(m)$ .

Au final, l'algorithme est en  $O(n+m)$ .

Automate quotient = automate minimal

Prop L'automate minimal de  $L$  est l'automate ayant le moins d'états possédant les automates déterministes complets.

dès 1)  $\text{ct}_1 = (\mathcal{Q}, A, S, I, F)$  est déterministe et complet.

$$I = \{i\} \quad \text{et} \quad \forall M \in RA^*, \forall a \in A \quad |S(a, a)| = |\{(m)^{-1}i\}| = 1$$

2) ct possède un nombre d'états minimal.

On commence par démontrer le lemme suivant:

lemme: Soit  $L$  un langage rationnel et  $\text{ct} = (\mathcal{Q}', A, S', I, F')$  un automate déterministe complet accessible reconnaissant  $L$ .

Pour  $q \in \mathcal{Q}'$ , on pose  $l(q(\alpha)) = \{w \in A^* / S'(q, w) \in F'\}$ .

$$\text{Alors } \mathcal{Q}' = \{l(q(\alpha)), q \in \mathcal{Q}\}.$$

Def: Un état  $q \in \mathcal{Q}'$  est dit accessible si il existe  $i \in I$ ,  $S'(i, q) = q$ .

$l(q)$  est accessible si tout état de  $\text{ct}$  est accessible.

dès du lemme: a)  $l(q) \subseteq \{l(q(\alpha)), q \in \mathcal{Q}\}$ .

Soit  $w \in A^*$ , comme  $\text{ct}$  est complet  $\exists i \in I, S'(i, w) = q$

$$\text{Donc } w \in l(i) \iff i w \in L \iff S'(i, i w) \in F' \iff S'(q, w) \in F' \iff w \in l(q(\alpha))$$

$$\text{Donc } \forall y, l(q(\alpha)) = l^{-1}(y) \subseteq \mathcal{Q} \quad \text{donc } \mathcal{Q} = \{l^{-1}(y), y \in A^*\} \subseteq \{l(q(\alpha)), q \in \mathcal{Q}\}.$$

b)  $\{l(q(\alpha)), q \in \mathcal{Q}\} \subseteq \mathcal{Q}$

Soit  $q \in \mathcal{Q}'$ , comme  $l(q)$  est accessible  $\exists u \in A^*, S'(i, u) = q$

on a comme précédemment  $l^{-1}(q) = l(q(\alpha))$  donc  $\{l(q(\alpha)), q \in \mathcal{Q}\} \subseteq \mathcal{Q}$ .

$$\text{Donc } \mathcal{Q} = \{l(q(\alpha)), q \in \mathcal{Q}\}$$

□

Retour à la preuve de la propriété:

D'après le lemme, tout automate déterministe complet accessible reconnaissant  $L$  vérifie que  $\mathcal{Q} = \{l(q(\alpha)), q \in \mathcal{Q}\}$  ie  $|\mathcal{Q}| \leq |\mathcal{Q}'|$ .

De plus comme tout automate déterministe complet peut être rendue accessible en automate déterministe complet accessible ayant moins d'états, on a donc que  $\text{ct}_2$

par l'automate déterministe complet reconnaissant  $L$  ayant le minimum d'états.  
 (car les états non-acceptables ne font partie d'aucun chemin accepté par l'automate).  $\square$ .

Prop Un langage est rationnel ssi il admet un nombre fini de quotients à gauche

$\Leftrightarrow$  soit  $L$  un langage rationnel, alors il existe un automate fini reconnaissant  $L$  noté et, et est équivalent à un automate fini déterministe complet  $\mathcal{A}'$ .

(Il faut réduire le nombre d'états de  $\mathcal{A}$ , on peut supposer qu'il est accueillant. On a alors d'après le lemme virtuel dans la preuve

Comme  $\mathcal{A}'$  est l'automate minimal de  $L$ , il a le nombre minimal d'états parmi les automates déterministes complets. donc  $|\mathcal{A}'| = |\{u \in A^*, u \in A^*\}| \leq |\text{états de } \mathcal{A}'| < \infty$

Dès  $L$  admet un nombre fini de quotients à gauche.

$\Leftrightarrow$  soit  $L$  un langage ayant un nombre fini de quotients à gauche

alors l'automate  $\mathcal{A}'$  est un automate fini reconnaissant  $L$ . donc  $L$  est rationnel.  $\square$

Vérification que  $L(\mathcal{A}') = L$ .

On montre par récurrence sur le rangien du mot  $u \in A^*$  que pour tout état  $x \in Q$ ,

$$\delta(x, u) = u^{-1}x.$$

•  $n=1$ :  $u \in A$  soit  $x \in Q$  alors  $\delta(x, a) = x = a^{-1}x$

$$\delta(x, a) = \delta(v^{-1}a, a) = (va)^{-1}a = \{w \in A^*, w \in \emptyset\} = \{w \in A^*, aw \in v^{-1}\} = \{w \in A^*, aw \in v\} = a^{-1}x$$

on suppose le résultat vrai pour  $k \in \mathbb{N}$  et on considère  $u \in A^*$ ,  $|u|=n+1$

on adois  $u = au'$  avec  $a \in A$  et  $u' \in A^*$  tel que  $|u'| = n$

$$\text{Soit } x \in Q \quad \delta(x, u) = \delta(x, au') = \delta(\delta(x, a), u') = \delta(a^{-1}x, u') = u'^{-1}(a^{-1}x) \quad \text{HR: 1}$$

$$\text{Or } u'^{-1}(a^{-1}x) = \{w \in A^*, u'w \in a^{-1}x\} = \{w \in A^*, au'w \in x\} = \{w \in A^*, au'w \in x\} = u'^{-1}x \quad \text{HR: 2}$$

Donc  $\forall u \in A^*, \forall x \in Q, \delta(x, u) = u^{-1}x$ .

$$w \in L(\mathcal{A}') \Leftrightarrow \delta(L, w) \cap F \Leftrightarrow w^{-1}L \cap F \Leftrightarrow w \in L \quad \text{def. def}$$

Ainsi  $L(\mathcal{A}') = L$ .