

909 LANGAGES RATIONNELS - EXEMPLES ET APPLICATIONS

(On supposera connues les définitions de : - automate fini déterministe (complétement) - automate fini non déterministe - automate fini non déterministe avec E-transitions et l'équivalence entre toutes ces automates. Par la suite, Σ désignera un alphabet fini.

I Langages rationnels et leurs caractérisations

La classe des langages rationnels est le premier niveau de la hiérarchie de Chomsky et peut être définie de beaucoup de manières différentes. En voici quelques-unes :

1) Une première définition [Aut.]

Définition [Langages rationnels]

La classe $\text{Rat}(\Sigma^*)$ des langages rationnels sur Σ est la plus petite famille de langages telle que :

- * $\emptyset \in \text{Rat}(\Sigma^*)$
- * $\forall a \in \Sigma \quad \{a\} \in \text{Rat}(\Sigma^*)$
- * $\text{Rat}(\Sigma^*)$ est close par union \cup (finie), par produit (\wedge concaténation) et par l'étoile.

Exemples : • $\Sigma \in \text{Rat}(\Sigma^*)$ car il s'écrit $\Sigma = \bigcup_{a \in \Sigma} \{a\}$

- Les mots de longueur paire forment un langage rationnel car égal à $(\Sigma\Sigma)^*$.
- Le langage des mots contenant le facteur $abba$ est rationnel car égal à $\Sigma^* a b b a \Sigma^*$.

2) Expressions rationnelles [Sat.]

Définition [Expressions rationnelles]: Une expression rationnelle sur Σ est une

formule obtenue inductivement de la manière suivante (on suppose que Σ ne contient pas les lettres ' \emptyset ', ' E ', ' $+$ ', ' \wedge ', ' $*$ ', ' * ')

- * \emptyset , E et a , pour tout a dans Σ sont des expressions rationnelles.

* Si E et F sont deux expressions rationnelles alors $(E+F)$, $(E.F)$ et $(E)^*$ sont des expressions rationnelles.

(Pour une meilleure lisibilité on enlèvera des parenthèses qui n'impliquent pas d'ambiguïté au niveau des expressions en imposant des priorités entre les opérations)

Ex : $-(a+b)^* a b b a (a+b)^*$

Définition À chaque expression rationnelle E on fait correspondre un langage noté $L(E)$ tel que :

- * $L(\emptyset) = \emptyset$ $L(E)$ = mot vide
- * $L(a) = \{a\}$ pour $a \in \Sigma$
- * $L(E+F) = L(E) \cup L(F)$ $L(E.F) = L(E).L(F)$
- * $L(E^*) = (L(E))^*$

Proposition Un langage est rationnel si et seulement si il est dénoté par une expression rationnelle. Il faut distinguer expression : élément syntaxique et le langage que l'élève dénote : sémantique

Ex : $(a+b)^*$ et $(a^*b)^*$ a * sont des expressions différentes mais les langages qu'elles dénotent sont les mêmes.

Définition Deux expressions sont dites équivalentes si elles dénotent le même langage.

Problème : Comment déterminer si deux expressions données sont équivalentes ?

3) Théorème de Kleene

Théorème de Kleene : Un langage L est rationnel si et seulement si il existe un automate fini et tel que $L = L(A)$

Des expressions aux automates [Sat.] p.155
La transition peut se faire de manière standard comme suit :


Union : $(L(A) \cup L(B))$




Produit : $(L(A).L(B))$



Étoile : $(L(A))^*$



Ex : $(a+b)^* a b b a (a+b)^*$



À noter : On peut directement obtenir un automate déterministe grâce à la méthode de Brzozowski (automate des dérivées)

Des automates aux expressions

Algorithme de McNaughton-Yamada :

On étiquette Q , ensemble des états d'un automate A , par $1, 2, \dots, n$.

Pour $(q, q') \in Q^2$ on définit alors $L^{(k)}_{q,q'} = \{a_1, \dots, a_n | q \xrightarrow{a_1} p_1 \xrightarrow{a_2} \dots \xrightarrow{a_n} q' \text{ et } p_1, p_2, \dots, p_n \in \{1, \dots, k\}\}$

On a les formules :

$$L^{(0)}_{q,q'} = \{a | q \xrightarrow{a} q'\} \cup \{q | q = q'\}$$

$$L^{(k+1)}_{q,q'} = L^{(k)}_{q,q'} + L^{(k)}_{q,p_{k+1}} (L^{(k)}_{p_{k+1}, p_{k+1}})^* L^{(k)}_{p_{k+1}, q'}$$

Et d'autre part : $L(A) = \bigcup_{B \in F} L_i^B$ où i est l'état initial

Élimination de Gauss : Lemme d'Aiden : Soit l'équation $X = AX + B$ où l'inconnue X est un langage.

$$\exists L \in E(A), \quad X = A^* B -$$

2, si $\epsilon \in A$ X est de la forme $X = A^*(B + P)$
où $P \subseteq \Sigma^*$.

Principe de la méthode: On appelle pour $p \in Q$ $L_p = \{w \mid \exists f \in F \quad w \xrightarrow{f} p\}$

On a donc $L(A) = L_i$, où i est l'état initial.

On résout alors le système

$$\begin{cases} L_p = \sum_{q \in Q} a L_q & + \epsilon \\ p \xrightarrow{a} q & \text{si } p \text{ est un état final} \end{cases}$$

en réduisant par substitutions successives les équations grâce au lemme d'Arden.

4) Autres caractérisations

a) Automate boustrophédon [Sak, p. 185]

Un automate boustrophédon est une machine de Turing dont la tête qui se déplace sur la bande est seulement une tête de lecture (et pas d'écriture).

Théorème: Un langage est rationnel si et il est reconnu par un automate boustrophédon.

(La preuve requiert la finitude des quotients à gauche pour un langage régulier)

b) Grammaires linéaires [Welp, p. 222]

Une grammaire est dite linéaire à droite (resp à gauche) si ces productions sont de la forme

$A \rightarrow wB$ ou $A \rightarrow w$ avec A, B non terminales, w une chaîne de terminales (resp $A \rightarrow Bw$ ou $A \rightarrow w$)

Proposition: Un langage est rationnel si et il est engendré par une grammaire linéaire (à gauche ou à droite)

Ex: $(a+b)^*$ alba $(a+b)^*$ est engendré par

$S \rightarrow aS1bS1$ alba T

T $\rightarrow aT1bT1E$.

(l'axiome est S)

II Conséquences du théorème de Kleene

1) Propriétés de clôture [Bog-Sel p. 83]

Propriété: La classe des langages rationnels est stable par:

- union (finie) \vdash def?
- intersection (finie)
- complémentation
- concaténation (finie)
- étoile
- image miroir

Théorème: L'image d'un langage rationnel par un homomorphisme fini reste un langage rationnel.

Corollaire: Pour L un langage rationnel, les ensembles suivants sont rationnels :

- préfixes (L) = $\{x \mid \exists y \in \Sigma^* \quad xy \in L\}$
- suffixes (L) = $\{y \mid \exists x \in \Sigma^* \quad xy \in L\}$
- infixes (L) = $\{z \mid \exists x, y \in \Sigma^* \quad xzy \in L\}$

Corollaire 2: L'image d'un langage rationnel par un morphisme (i.e. une application h telle que $\forall x, y \in \Sigma^* \quad h(x \cdot y) = h(x) \cdot h(y)$) est un langage rationnel.

Propriété: Pour L langage rationnel et K un langage quelconque, le quotient à gauche de L par K est $K^*L = \{y \mid \exists x \in K \quad xy \in L\}$ et le quotient à droite de L par K i.e. $LK^{-1} = \{x \mid \exists y \in K \quad xy \in L\}$ sont des langages rationnels.

2) Lemme(s) de l'étoile et variante [Bog p. 84]

Définition: Facteur itérant. Un mot v est dit facteur itérant d'un langage L lorsque il existe $n \in \mathbb{N}$ tel que $v^n \in L$ et $v \in L$.

Lemma de l'étoile 1: Dans un langage rationnel, tout mot suffisamment long contient un facteur itérant non vide.

Application: $\{a^n b^n \mid n \in \mathbb{N}\}$ n'est pas rationnel.

*: notion supposée connue

Lemma de l'étoile 2: Dans un langage rationnel L , tout facteur suffisamment long v contient un facteur itérant non vide i.e. il existe un entier N tel que pour tout b dans L et toute factorisation $b = g_1 h g_2$ telle que $|h| > N$, il existe une factorisation de $h = vvv$, avec $v \neq \epsilon$ telle que $g_1, v, v^* \in g_2 \cap L$.

Application: $\{a^n b^n \mid n \in \mathbb{N}\} \cup \Sigma^* \backslash \{a^n b^n \mid n \in \mathbb{N}\}$ n'est pas rationnel.

Lemma de l'étoile par bloc: Si L est rationnel, il existe $N \geq 0$ tel que pour tout $b \in L$ et toute factorisation de la forme $b = v_1 v_2 \dots v_n w$, où $v_i \neq \epsilon$ il existe (j, k) , $0 \leq j \leq k \leq N$, tel que: $v_1 v_2 \dots v_j (v_{j+1} \dots v_k) v_{k+1} \dots v_n w \in L$

Application: $\{(aab)^n (abb)^m \mid n, m \in \mathbb{N}\} \cup \Sigma^* \backslash \{(aab)^n (abb)^m \mid n, m \in \mathbb{N}\}$ n'est pas rationnel.

Théorème: [Bog-Sel p. 84] Un langage L est régulier si il existe $N \geq 0$ tel que pour tout $w \in L$ avec $|w| \geq N$ il existe une factorisation $w = xyz$, $y \neq \epsilon$ tel que :

$$\forall i \in \mathbb{N} \quad \forall v \in \Sigma^* \quad (wv \in L \Leftrightarrow xy^iz \in L)$$

Théorème: L'ensemble des facteurs itérants d'un langage rationnel forme un langage rationnel. DVP

3) Quotients

[Bog p. 84]

Définition: Quotient gauche, quotient droit. Les quotients gauche et droit d'un langage L par un mot w sont respectivement :

$$w^{-1}L = \{v \mid vw \in L\} \quad \text{et} \quad Lw^{-1} = \{u \mid uw \in L\}$$

Notons que $\epsilon^{-1}L = L$ et $(uv)^{-1}L = u^{-1}(v^{-1}L)$

Proposition: Soit L un langage reconnu par un automate A , on note pour $q \in Q(A)$ $L_q = \{w \in \Sigma^* \mid \text{il y a un état final de } A$

Alors les L_q décrivent l'ensemble des quotients gardés.

Théorème: Un langage est rationnel si et seulement si il admet un nombre fini de quotients gauche.

$$\text{Ex: } L = (ab)ab(a+b)^* \Rightarrow a^{-1}L = L + b(a+b)^*$$

$$a^{-1}L = L; (ab)^{-1}L = (a+b)^*; (aa)^{-1}L = L; (aba)^{-1}L = (abb)^{-1}L = (a+b)^*$$

III Minimisation des automates

Motivation de cette partie?

* Obtenir un procédé efficace (principalement au niveau de l'occupation mémoire) pour déterminer si un mot donné appartient à un langage rationnel finisé ou pas (aspect pratique)

* Pouvoir tester l'équivalence de deux expressions rationnelles (aspect théorique)

1) Automate minimal et équivalence de Nerode [Bij p.315]


Définition [Équivalence de Nerode]

Pour un automate $A = (Q, \Sigma, \delta, \iota, F)$ on définit une relation d'équivalence sur Q appelée équivalence de Nerode définie comme

$$p \sim q \iff L_p = L_q \iff \forall u \in \Sigma^* \delta(p, u) \in F \Leftrightarrow \delta(q, u) \in F$$

On notera $A/\sim = (Q/\sim, \Sigma, \bar{\delta}, \bar{\iota}, \bar{F})$ l'automate A quotient par \sim (Q/\sim est l'ensemble des classes de la relation \sim et $\bar{\delta}: (\bar{q}, a) \mapsto \delta(q, a)$ est bien définie car \sim est régulière à droite)

Théorème: L'automate minimal est l'automate ayant le moins d'états parmi les automates déterministes complets qui reconnaissent L . Il est unique à isomorphisme près. Il est égal à A/\sim , mais aussi à l'automate des quotients.



Application: On peut décider si oui ou non deux expressions données sont équivalentes

2) Calcul de l'automate minimal [car p.55]

Méthode de Nerode: (On fixe $\alpha = (Q, \Sigma, \delta, \iota, F)$ déf.)

Proposition: L'équivalence de Nerode est la relation d'équiv. - sur Q régulière à droite (i.e. $p \sim q \Rightarrow \delta(p, a) \sim \delta(q, a)$) la plus grossière qui est plus fine que $\delta, \bar{\delta}$.

On définit alors une suite (v_i) telle que $q \sim v_i \Leftrightarrow (q \in F \Leftrightarrow v_i \in F)$

$q \sim v_i \sim v_{i+1} \Leftrightarrow (q \sim v_i \text{ et } \forall a \in \Sigma \delta(q, a) \sim \delta(v_i, a))$

Si $v_k = v_{k+1}$, alors v_k est l'équivalence de Nerode (l'algorithme est en $O(mn^2)$)

Algorithme de Hopcroft:

Définition [Stabilité] Soient PCQ, RCQ et $a \in \Sigma$

P est dit stable pour (R, a)

ssi $P \cap a^{-1}R = P \cap a^*R$.

Si non P est dit instable pour (R, a)

i.e. $P \cap a^{-1}R \neq \emptyset$ et $P \cap a^*R \neq \emptyset$

Une partition P de Q est stable pour (R, a) si $\forall P \in P$ P est stable pour (R, a)

P est dite stable (tout court) si $\forall R \in P$ P est stable pour (R, a) .

P est dite stable (tout court) si $\forall R \in P$ P est stable pour (R, a) .

Proposition: Une relation d'équiv sur Q est régulière à droite si la partition associée est stable.

Théorème: L'algorithme dit de Hopcroft minimise l'automate et

en une complexité $O(mn \log n)$ où $m = \text{card}(\Sigma)$ et $n = \text{card}(Q)$ (l'important sera explicité mais non prouvé)

IV Applications

1) En biologie, en mathématiques [Rez p.41]

• À l'origine introduit pour modéliser les réseaux

• Peut être utilisée pour résoudre des problèmes de combinatoire ...

2) Reconnaissance de motifs [Rez p.63 p.64]

On veut chercher un mot w dans un texte.

Concrètement on veut reconnaître le langage Σ^* et Σ^* (ou $\Sigma^* w$) (exemple repris durant toute cette leçon !)

avec $w = abba$
On note $\text{Pref}(w) = \text{ensemble des préfixes de } w$

$B_w = (\text{Pref}(w), \Sigma, \delta, \{ \epsilon \}, \{ w \})$
avec $\delta(p, a) = \text{le plus long préfixe de } pa \text{ dans Pref}(w)$

Théorème: B_w reconnaît $\Sigma^* w$. De plus, il s'agit de l'automate minimal.

3) Analyse lexicale [WH p.209]

C'est la première étape d'un compilateur. Elle précède l'analyse syntaxique.

Elle est chargée de lire un programme source (sous forme d'une suite de caractères) afin de le décomposer en une succession d'unités lexicales, appelées tokens.


Ex de lexèmes: Entrée, Identificateur, mots réservés au langage (comme begin, if, int)

Pour ex, on veut reconnaître le langage $l(lch)^* + ch(ch^*)^* + ch(ch^*)^* Edch$

ID INT REAL

où $ch = l, 1, 2, \dots, 9$ et $l = a, b, \dots, z$

On peut alors déterminiser et minimiser l'automate suivant.



ANNEXES

À propos des références

[Cor] Carton : Un des plus clairs sur le sujet à mon avis

[Sak] Sakarovitch : Complet, bien expliqué, j'aime beaucoup, il a juste un humeur assez longue

[Reg-Sal] Rosenberg - Salomaa (Handbook of Formal Languages)

Livre super théorique, en anglais, mais pas mal expliqué -

[Bq] Beauquier (éléments d'Algorithmique) Si, si, on parle des

automates dans le Beauquier, j'aime bien la partie sur les mi-

Mais aussi :

[Wol] Wolper

Approfondissement intéressant (d'après l'auteur) mais je

m'en ai pas eu besoin -

(les compléments) Ne comment -

À propos du plan : la partie apparemment contestable devrait être la minimisation des automates - Moi je suis convaincu que ça

a sa place ici, à vous de faire votre choix (et votre avis) -

• Je déconseillerais de parler de dérivations des expressions rationnelles / hauteurs d'échelle / langages sous état. C'est trop

théorique avec peu d'application pratique ! Non sûr que ça

plaît aux jury - (qui n'est pas indispensable dans ce que j'ai mis)

• Bien sûr tout n'est pas indispensable donc ce que j'ai mis

j'ai été même parfois (un peu) redondant - Il aurait également fallut que je précise un peu mieux les notations utilisées

À propos des développements les développements que je propose, à

base de la régularité des facteurs itérants et l'algorithme de Hopcroft

sont plutôt longs et pas du genre faciles je pense - le second a le

gross ouantage de nouveau se reculer dans 3 besoins (dont celle

sur Diverier nous rejoindre) Un investissement rentable ? (C'est il y a du bétail,

J'ouvre nous aussi à :

- TR de Kleene

- localisation / Automates des préfixes (dès d'ailleurs que)

- équivalence avec les grammars linéaires

- Méthode de Brzozowski - complexité optimale de l'espace de l'écriture

de 2 esp. rationnelles