

NOM : BERNARD

Prénom : Sophie

Jury :

Algèbre ← Entourez l'épreuve → Analyse Info

Sujet choisi : 909. Langages rationnels. Exemples et applications

Autre sujet :

<p>On note <math>A</math> un alphabet</p> <p><b>1. PREMIERES PROPERTIES DES LANGAGES RATIONNELS</b></p> <p><u>1. Définition et lien avec les expressions rationnelles</u></p> <p>Def 1: Soient <math>K</math> et <math>L</math> des langages. On définit:</p> <p>(i) La concaténation: <math>KL = \{uv, u \in K, v \in L\}</math>          (ii) Stabilité: <math>L^0 = \{\epsilon\}</math>, <math>L^{k+1} = L^k \cdot L</math> et <math>L^* = \bigcup_{n \geq 0} L^n</math> (<math>k \geq 0</math>)</p> <p>Def 2: L'ensemble <math>Rat(A^*)</math> des langages rationnels sur <math>A</math> est la plus petite famille de langages vérifiant:</p> <p>(i) <math>\emptyset \in Rat(A^*)</math>, <math>\forall a \in A, \{a\} \in Rat(A^*)</math>          (ii) <math>Rat(A^*)</math> est stable pour les trois opérations rationnelles (union, concaténation, étoile)</p> <p>Ex 3: Les langages suivants sont rationnels. (<math>\epsilon \in \emptyset^*</math>, <math>A, \emptyset</math> de langage des mots de longueur paire: <math>(AA)^*</math> Les langages contenant un certain motif <math>m \in A^*</math>: <math>A^* m A^*</math></p> <p>Def 4: On définit de manière inductive l'ensemble des expressions rationnelles <math>Rat(A^*)</math> par:</p> <p>(i) <math>\emptyset \in Rat(A^*)</math>, <math>\epsilon \in Rat(A^*)</math>, et <math>\forall a \in A, a \in Rat(A^*)</math>          (ii) <math>\forall E, F \in Rat(A^*)</math>, <math>E + F \in Rat(A^*)</math>, <math>EF \in Rat(A^*)</math> et <math>E^* \in Rat(A^*)</math>          (iii) <math>\forall E, F \in Rat(A^*)</math>, <math>\mathcal{Z}(E + F) = \mathcal{Z}(E) \cup \mathcal{Z}(F)</math>, <math>\mathcal{Z}(EF) = \mathcal{Z}(E)\mathcal{Z}(F)</math> et <math>\mathcal{Z}(E^*) = (\mathcal{Z}(E))^*</math></p> <p>Def 5: Soit <math>E \in Rat(A^*)</math>. On note <math>\mathcal{Z}(E)</math> le langage reconnu par <math>E</math>, défini de manière inductive par:</p> <p>(i) <math>\mathcal{Z}(\emptyset) = \emptyset</math>, <math>\mathcal{Z}(\epsilon) = \{\epsilon\}</math> et <math>\forall a \in A, \mathcal{Z}(a) = \{a\}</math>          (ii) <math>\forall E, F \in Rat(A^*)</math>, <math>\mathcal{Z}(E + F) = \mathcal{Z}(E) \cup \mathcal{Z}(F)</math>, <math>\mathcal{Z}(EF) = \mathcal{Z}(E)\mathcal{Z}(F)</math> et <math>\mathcal{Z}(E^*) = (\mathcal{Z}(E))^*</math></p> <p>Prop 6: Les expressions rationnelles sont un outil syntaxique très pratique pour définir un automate. C'est seulement la définition 5 qui leur donne une structure.</p> <p>Th 7: Soit <math>L</math> un langage sur <math>A</math>.  <math>L \in Rat(A^*) \iff \exists E \in Rat(A^*)</math>, <math>\mathcal{Z}(E) = L</math></p> <p>Ex 8: En posant <math>L = A^*</math> avec <math>A = \{a, b\}</math>, alors:  <math>L = \mathcal{Z}((a+b)^*) = \mathcal{Z}((a^*b^*)^* a^*)</math></p> <p>Prop 9: <math>\forall L, m, n \geq 0</math>, pas forcément consécutifs de l'expression rationnelle associée à un langage (sur <math>\{a, b\}</math>). Cela pose deux problèmes: + peut-on décider si pour <math>E, F \in Rat(A^*)</math>, alors <math>\mathcal{Z}(E) = \mathcal{Z}(F)</math>? + peut-on savoir si pour <math>E \in Rat(A^*)</math>, alors <math>\mathcal{Z}(E) = A^*</math>? * On utilise souvent des notations des expressions rationnelles pour les langages rationnels, car peut être parfois pas faire la distinction.</p>	<p><u>2. Lien avec les automates finis</u></p> <p>Def 10: Un automate <math>\mathcal{A}</math> sur un alphabet <math>A</math> est un quadruplet <math>(Q, A, \Delta, I, F)</math> où <math>Q</math> est fini (ensemble des états), <math>I \subset Q</math> (états initiaux), <math>F \subset Q</math> (états finaux), et <math>\Delta \subset Q \times A \times Q</math> (ensemble des transitions). Si <math>(p, a, q) \in \Delta</math> on note <math>p \xrightarrow{a} q</math> la transition.</p> <p>Def 11: Le langage reconnu par un automate <math>\mathcal{A}</math> est l'ensemble des mots qui sont étiquetés d'un chemin fini acceptant de <math>\mathcal{A}</math> (automate, c'est à dire d'une suite finie de transitions consécutives dont le premier état est initial, et le dernier état est final). On le note <math>\mathcal{Z}(\mathcal{A})</math>.</p> <p>Ex 12: <math>\mathcal{Z}</math> automate <math>\mathcal{A}_1 = (Q, A, \Delta, I, F)</math> (<math>Q = \{1, 0, 2\}</math>, <math>I = \{1, 0, 2\}</math>, <math>F = \{2\}</math>, <math>\Delta = \{(1, a, 1), (1, b, 1), (1, a, 2), (2, b, 2), (2, a, 1)\}</math>, <math>\{1, 1, 1, 1, 1\}</math> est représenté en arabe (Fig. 1) et reconnaît le langage <math>(ab)^* a^*</math>.</p> <p>Th 13 (Kleene): Soit <math>L</math> un langage sur <math>A</math>.  <math>L \in Rat(A^*) \iff \exists \mathcal{A}</math> automate fini sur <math>A</math>, <math>\mathcal{Z}(\mathcal{A}) = L</math>.</p> <p>Algo 14 (Thompson): Construction inductive d'un automate avec <math>\epsilon</math>-transitions reconnaissant la même langue qu'une expression régulière. On peut par la suite modifier l'automate, par lequel on fait plus de transitions. (Voir annexe Fig 2 pour la construction inductive).</p> <p>Algo 15 (Néanmoins et Yarnold): Calcul du langage rationnel reconnu par un automate fini en commençant par numérotter les états de <math>1</math> à <math>n</math>, puis calculer récursivement <math>L_{pq}(k)</math> pour <math>k \geq 0</math>, le langage reconnu entre les états <math>p</math> et <math>q</math> en ne passant que par des états dont le numéro est <math>\leq k</math>. On a alors <math>\bigcup_{i \in I, j \in F} L_{ij}(n)</math>.</p> <p>Def 16: Un automate <math>(Q, A, \Delta, I, F)</math> est déterministe s'il n'a qu'un seul état initial et si <math>\forall p \xrightarrow{a} q, p \xrightarrow{a} q'</math>, <math>q = q'</math>. Un automate <math>(Q, A, \Delta, I, F)</math> est complet si pour toute paire <math>(p, a)</math> <math>\in Q \times A</math>, il existe <math>q \in Q</math>, <math>p \xrightarrow{a} q</math> est une transition.</p> <p>Prop 17: L'ensemble des langages reconnus par des automates finis déterministes ou déterministes complets est exactement l'ensemble des langages rationnels.</p> <p>Ex 18: Les automatistes de la figure 3 reconnaissent tous les mots du langage <math>(a+b)^* a^*</math>.</p> <p>Prop 19: <math>Rat(A^*)</math> est clos par complémentation et intersection.</p> <p>Prop 20: Soit <math>E \in Rat(A^*)</math>. Le problème de l'unicité de <math>\mathcal{Z}(E)</math> (savoir si <math>\mathcal{Z}(E) = A^*</math>) est PSPACE-complet.</p>
---	--

**II - PROPRIETES LIÉES AUX AUTOMATES FINIS**

1 - Lemmes de états

**Lemme 21** (de détails au langage au relation): Soit L un langage rationnel sur A. Il existe m entier tel que pour tout mot p de L,  $|i| \leq m$  alors:

3.  $u, v, w \in A^*$ ,  $u \neq \epsilon$ ,  $p = uvw$  et  $uv^m w \in L$ .

**Ex 22**:  $L = \{a^n b^n\}$ ,  $m \geq 0$  n'est pas rationnel.

**Prop 23**: On a seulement une condition nécessaire pour être un langage rationnel.

**Ex 24**:  $A_1 = \{a, b\}$ ,  $L_{A_1} = A_1^*$  ou  $A_1^*$  vérifie les conditions du lemme de détails mais n'est pas rationnel.

**Lemme 25** (de détails voir au par bres): Soit L un langage rationnel sur A. Il existe m entier tel que pour tout mot p = uvw tel que  $u \neq \epsilon$ , alors:

3.  $i, j, 0 \leq i < j \leq m$ ,  $uv^i w, uv^j w, uv^m w \in L$ .

**Def 26**: Un langage L vérifie la propriété  $\pi_k$  (resp.  $\pi_k^*$ ) pour  $k \geq 0$  si pour toute factorisation  $p = uv^k w$ ,  $u \neq \epsilon$  et dans les v, u sont des mots non vides, il existe deux indices  $0 \leq i < j \leq k$  tels que:

Pour  $\pi_k$ :  $\forall m \geq 0$ ,  $\exists \ell \in \mathbb{N}$ ,  $\exists i, j, m \leq i < j \leq m + \ell$ ,  $u^i v^m w^j \in L$ .

Pour  $\pi_k^*$ :  $\exists \ell \in \mathbb{N}$ ,  $\forall m \geq 0$ ,  $\exists i, j, m \leq i < j \leq m + \ell$ ,  $u^i v^m w^j \in L$ .

**TR 23** (Ehrenfeucht, Rabin et Regeberg): Soit L un langage sur A. Les propositions suivantes sont équivalentes:

- (i) L est rationnel
- (ii) Il existe  $k \geq 0$  tel que L vérifie  $\pi_k$
- (iii) Il existe  $k \geq 0$  tel que L vérifie  $\pi_k^*$

**Lang 28**: On a donc deux nouvelles caractérisations des langages rationnels, et deux lemmes très utiles pour montrer la non-rationnalité d'un langage.

2 - Résolution d'équations

**Lemme 29** (Andon): Soient K et L deux langages sur A. On considère l'équation  $X = KX + L$  d'inconnue X un langage.

- (i) Si  $\epsilon \notin K$ , la relation est  $X = K^* L$ .
- (ii) Si  $\epsilon \in K$ , les solutions sont de la forme  $X = K^*(L + Y)$  où  $Y \in A^*$ .

**Algo 30** (Élimination de Gauss): Calcul du langage reconnu par un automate par utilisation système linéaire du lemme d'Andon. On note  $X_q$

l'ensemble des mots qui échantillent un chemin de q à un état final. On obtient alors un système d'équations et finalement l'ensemble L du langage reconnu par l'automate.

3 - Par les résiduels: automate minimal

**Def 31**: Soit L un langage sur A. Le résiduel au quotient à gauche de L par un mot  $u \in A^*$  est  $u^{-1}L = \{v, uv \in L\}$ . Le résiduel de L par un langage  $K \subset A^*$  est  $K^{-1}L = \bigcup_{k \in K} k^{-1}L$ . L'ensemble des résiduels de L est  $\{A^* \}^{-1}L$ .

**Prop 32**: Pour toute partie a de A, tous mots u, v et w de  $A^*$ , et tous langages K et L sur A on a:

- (i)  $u^{-1}(K+L) = u^{-1}K + u^{-1}L$
- (ii)  $a^{-1}(KL) = (a^{-1}K)L + \epsilon(K)$  avec  $\epsilon(K) = \epsilon \cap L$
- (iii)  $u^{-1}(KL) = (u^{-1}K)L + \sum_{uv=u} u^{-1}K)v^{-1}L$
- (iv)  $a^{-1}(L^*) = (a^{-1}L)^*$
- (v)  $u^{-1}(L^*) = \sum_{uv=u} u^{-1}L)v^{-1}L^*$
- (vi)  $(auv)^{-1}L = u^{-1}(av^{-1}L)$ .

**Ex 33**: On s'intéresse aux résiduels de  $L = (ab^*a + b)^*$

$a^{-1}L = b^*aL$ ;  $b^{-1}L = L$ ;  $(b^*)^{-1}L = L$ ;  $(ab^*)^{-1}L = b^*aL$   
 $(b^*ab^*)^{-1}L = b^*aL$  et  $(ab^*b^*)^{-1}L = L$ .

**Prop 34**: Soit L un langage rationnel sur A. L a un membre fini de résiduels.

**Def 35**: Soit L un langage rationnel sur A. Son automate minimal est  $\mathcal{A}_L = (\mathcal{Q}, A, \Delta, I, F)$  avec:

$\mathcal{Q} = \{u^{-1}L, u \in A^*\}$ ,  $I = \{L\}$ ,  $F = \{u^{-1}L, u \in L\}$  et  $\Delta = \{u^{-1}L \xrightarrow{a} (aua)^{-1}L, u \in A^*, a \in A\}$

**Ex 36**: En annexe, on la Fig 4 est représenté l'automate minimal du langage de l'exemple 33:  $L = (ab^*a + b)^*$

**Lemme 37**: Pour tout langage rationnel L sur A,  $\mathcal{A}_L$  accepte exactement L, et il n'y a pas d'automate avec moins d'états que l'automate L.

**Lemme 38**: Un langage L est rationnel si et seulement si il a un nombre fini de résiduels.

4 - Construction de l'automate minimal

**Def 39**: Soit  $\mathcal{A} = (\mathcal{Q}, A, \Delta, I, F)$  un automate déterministe complet. On note par toute paire  $(p, a) \in \mathcal{Q} \times A$ ,  $p \cdot a$  l'unique état tel que  $p \xrightarrow{a} p \cdot a$  soit une transition de  $\mathcal{A}$ , puis par tout mot u de  $A^*$ ,  $p \cdot u = (p \cdot u) \cdot a$ . On appelle congruence de l'état p la relation d'équivalence:  $u, v \in \mathcal{Q}$ ,  $q \cdot u, q \cdot v \in A^*$ ,  $q \cdot u \in F$  et  $q \cdot v \in F$

l'ensemble des mots qui échantillent un chemin de q à un état final. On obtient alors un système d'équations et finalement l'ensemble L du langage reconnu par l'automate.

**Def 40**: Soit  $\mathcal{A} = (\mathcal{Q}, A, \Delta, I, F)$  un automate déterministe complet. L'automate quotient  $\mathcal{A}/\sim$  est  $(\mathcal{Q}/\sim, A, \Delta', I', F')$  avec  $\Delta' = \{(q, a) \xrightarrow{a} (q \cdot a)\}$ ,  $q \in \mathcal{Q}$ ,  $a \in A$ .

**Ex 41**: En annexe, on la Fig 5 est représenté l'automate quotient du langage de l'exemple 33:  $L = (ab^*a + b)^*$

**Prop 42**: Soit L un langage sur A et  $\mathcal{A}_L$  son automate déterministe complet reconnaissant L. Alors l'automate quotient  $\mathcal{A}_L/\sim$  est isomorphe à l'automate minimal  $\mathcal{A}_L$ .

**Prop 43**: Soient E et F deux expressions rationnelles. Le problème de savoir si  $\mathcal{Z}(E) = \mathcal{Z}(F)$  est décidable.

**Algo 44** (Hopcroft): Cet algorithme permet de calculer l'automate quotient de la congruence de Nerode d'un automate déterministe complet  $\mathcal{A} = (\mathcal{Q}, A, \Delta, I, F)$ , en temps  $O(|\mathcal{A}| | \mathcal{Q}| \log |\mathcal{Q}|)$ , par raffinement de partitions.

**III - AUTRES CARACTERISATIONS ET APPLICATIONS**

1 - Lien avec les morphismes de monoides

**Def 45**: Un monoïde est un ensemble fini non vide de composition interne associative qui possède un élément neutre, noté  $1_N$ . Soient  $N$  et  $N'$  deux monoïdes. Un morphisme de  $N$  dans  $N'$  est une application  $\mu: N \rightarrow N'$  vérifiant:  $\mu(1_N) = 1_{N'}$  et  $\forall x, y \in N$ ,  $\mu(xy) = \mu(x)\mu(y)$

**Def 46**: Un langage L sur A est reconnu par un morphisme de monoïde  $\mu: A^* \rightarrow N$  s'il existe une partie P de N telle que  $L = \mu^{-1}(P)$ . Un monoïde N reconnaît le langage L s'il existe un morphisme  $\mu: A^* \rightarrow N$  qui reconnaît L.

**Prop 47**: Soit L un langage sur A. L est rationnel si et seulement si il existe un automate par un monoïde fini.

**Ex 48**:  $\mathbb{Z}/2\mathbb{Z}$  reconnaît  $(ab^*a + b)^*$ , car:  
 $\mu: A^* \rightarrow \mathbb{Z}/2\mathbb{Z}$  est un morphisme de monoïde et  $\mu^{-1}(\{0\}) = (ab^*a + b)^*$ .

**Prop 49**: Soient B un alphabet et  $\mu$  un morphisme de  $A^*$  dans  $\mathcal{B}^*$ . Si L (resp. R) un langage sur A (resp. B), est rationnel, alors  $\mu(L)$  (resp.  $\mu^{-1}(R)$ ) est rationnel.

**Appl S0:** Soient  $B$  un alphabet,  $K$  un langage sur  $B$ . Soit  $\tau$  une substitution de  $A^*$  dans  $B^*$ , c'est-à-dire un imbedding de  $A^*$  dans  $B^*$ . Les parties de  $B^*$  issues de l'opération de produit: Alors  $K(u)$ ,  $\tau(u)$   $\neq \emptyset$  et  $(u, \tau(u)) \in K$  sont rationnels.

**2. Recherche de motifs dans un texte**

On veut chercher dans un document un mot, ou son nombre d'occurrences. Cela revient à essayer de reconnaître le langage rationnel composé exactement de ce mot.

**Algo S1 (Algorithme de Simon):** C'est une amélioration de l'algorithme de Knuth. On part avec des automates, on deux phases. La première phase dite de préparation, est de complexité  $O(mn)$  en espace et en temps, la seconde, de recherche, en  $O(mn)$  en temps, où  $m$  est la longueur du motif à chercher et  $n$  la longueur du texte dans lequel chercher.

**Appl S2:** En hautement de texte, pour implémenter la recherche on la ramène à un motif. C'est le gap de l'index qui permet de chercher à partir d'une expression rationnelle.

**3. Automatique de Presburger**

**Appl S3:** On considère la fonction de primitive des entiers mutuels de l'addition dont la signature est:  $\phi = (x=y) \mid (x+y=z) \mid \phi \vee \psi \mid \neg \phi \mid \exists z \phi$ . Alors pour toute formule close  $\phi$ , il est décidable de savoir si  $\phi$  est vraie.

**4. Analyse lexicale**

**Appl S4:** C'est la première étape d'un compilateur. On veut reconnaître un ensemble de langages rationnels (les mots-clés, identificateurs, nombres, ...) dans un langage rationnel. On peut la faire grâce à l'équivalence langages rationnels automatiques et les algorithmes associés. C'est la présence des outils comme lex et yacc.

**5. Lien avec les grammaires régulières.**

**Def S5:** Une grammaire régulière (ou alg. (casp. états)) est un quadruplet  $G = (N, A, P, S)$  où  $N$  est un alphabet de symboles non terminaux,  $A$  un alphabet de symboles terminaux,  $P$  est l'ensemble des règles de production avec  $P \subseteq N \times (N^* A^* \cup A^* \epsilon)$ .

Casp.  $P \subseteq N \times (N^* A^* \cup A^* \epsilon)$ , où  $S$  est symbole initial, et  $S \in N$ .

**Lemme S6:** Les langages reconnus par une grammaire régulière sont exactement les langages rationnels.

**Ex S7:** La grammaire  $G = (N, T, \{a, b\}, K(S, b), (S, bS), (aT, S, aT), (T, bT), (T, aS), (S, S))$  reconnaît le langage  $(ab^*a + b)^*$  qui est rationnel. On peut aussi le représenter sans forme d'automate (Fig 6).

Fig 1. Ex 12:






Fig 2. Algo 14:



union de  $S$  et  $T$ :  $S \rightarrow \textcircled{1} \textcircled{2} \textcircled{3} \textcircled{4} \textcircled{5} \textcircled{6}$



concaténation de  $S$  et  $T$ :



Étoile de  $S$ :



Fig 3. Ex 18: Norm d'écriture:



Déterminisme:






Fig 3 - ex 18



Déterministe:



Déterministe complet:




Fig 4 - ex 36




Fig 5 - ex 41





Fig 6 - ex 57



Relevance: Contain:

langages formels, calculabilité et complexité