

MPRI, Fondations mathématiques de la théorie des automates

Olivier Carton, Jean-Éric Pin

Examen du 2 mars 2015, 12h 45. Durée: 2h 30, notes de cours autorisées

Avertissement : On attachera une grande importance à la clarté, à la précision et à la concision de la rédaction.

Soit A un alphabet. Les langages considérés dans ce problème sont des langages réguliers de A^* .

On dit qu'un langage S *sépare* deux langages K et L si $K \subseteq S$ et $L \cap S = \emptyset$. Plus généralement, si \mathcal{F} est une **algèbre de Boole de langages** de A^* , on dit que K et L sont \mathcal{F} -*séparables* s'il existe un langage de \mathcal{F} qui sépare K et L .

On s'intéresse au *problème de la séparation* pour \mathcal{F} : peut-on décider si deux langages réguliers donnés sont \mathcal{F} -séparables?

1. Généralités et exemples

Question 1. Montrer que L et L^c sont \mathcal{F} -séparables si et seulement si $L \in \mathcal{F}$.

Question 2. Soient $(K_i)_{1 \leq i \leq n}$ et $(L_j)_{1 \leq j \leq m}$ deux familles finies de langages réguliers. Montrer que les langages $\bigcup_{1 \leq i \leq n} K_i$ et $\bigcup_{1 \leq j \leq m} L_j$ sont \mathcal{F} -séparables si et seulement si chaque paire (K_i, L_j) est \mathcal{F} -séparable.

Question 3. On prend pour \mathcal{F} la classe des langages sans-étoile. Montrer que les langages $(a^2)^*$ et $(a^2)^*a$ ne sont pas \mathcal{F} -séparables, mais que les langages $(ab)^+$ et ba^* le sont.

Question 4. On prend pour \mathcal{F} la classe des langages testables par morceaux. Montrer que les langages $(ab)^+$ et $(ba)^+$ ne sont pas \mathcal{F} -séparables, mais que les langages $(a^2)^*$ et $(b^2)^*b$ le sont. Montrer qu'il n'existe cependant pas de \mathcal{F} -séparateur minimal pour ces langages.

Dans les questions 5 et 6, on prend pour \mathcal{F} la classe des langages dont le monoïde syntactique est idempotent et commutatif. On rappelle que ce sont les langages qui sont combinaisons booléennes de langages de la forme A^*aA^* , avec $a \in A$, ou encore les langages qui sont combinaisons booléennes de langages de la forme B^* , où $B \subseteq A$.

Question 5. Si $A = \{a, b, c\}$, montrer que $(ab)^+$ et $(ac)^+$ sont \mathcal{F} -séparables mais que $(a(b+c))^+$ et $(ba)^+$ ne sont pas \mathcal{F} -séparables.

Question 6. Montrer que le problème de la séparation pour \mathcal{F} est décidable.

2. Ensembles ponctuels

Soit M un monoïde et soit \mathbf{V} une variété de monoïdes finis. On dit qu'une partie X de M est \mathbf{V} -*ponctuelle* si, pour tout morphisme relationnel $\tau : M \rightarrow T$, avec $T \in \mathbf{V}$, il existe un élément $t \in T$ tel que $X \subseteq \tau^{-1}(t)$.

Question 7. Soit M le semigroupe $\{1, a, b, 0\}$ dans lequel le produit de deux éléments différents de 1 est égal à 0. On prend pour \mathbf{V} la variété des semigroupes idempotents et commutatifs. Montrer que les parties $\{a, 0\}$ et $\{b, 0\}$ de M sont \mathbf{V} -ponctuelles, mais que $\{a, b\}$ ne l'est pas.

Dans la suite du problème, on prend pour \mathcal{F} l'algèbre de Boole des langages de A^* reconnus par un monoïde de \mathbf{V} .

Question 8. Soit M un monoïde fini et soit $\pi : A^* \rightarrow M$ un morphisme surjectif. Soient p et q deux éléments de M . On suppose que les langages $\pi^{-1}(p)$ et $\pi^{-1}(q)$ sont séparables par un langage S de \mathcal{F} . Soit $\gamma : A^* \rightarrow N$ le morphisme syntactique de S et soit $\tau : M \rightarrow N$ le morphisme relationnel $\gamma \circ \pi^{-1}$. Montrer que $\tau(p)$ et $\tau(q)$ sont disjoints et en déduire que $\{p, q\}$ n'est pas un ensemble \mathbf{V} -ponctuel de M .

Question 9. Montrer réciproquement que si $\{p, q\}$ n'est pas un ensemble \mathbf{V} -ponctuel de M , alors les ensembles $\pi^{-1}(p)$ et $\pi^{-1}(q)$ sont \mathcal{F} -séparables.

Question 10. Montrer que le problème de la séparation pour \mathcal{F} est équivalent au problème suivant: étant donné un monoïde fini M quotient de A^* et deux éléments $p, q \in M$, décider si la partie $\{p, q\}$ est \mathbf{V} -ponctuelle.

3. Langages testables par morceaux

Question 11. Soit $(u_n)_{n \geq 0}$ une suite de mots de A^* telle que pour tout n , u_n soit un sous-mot de u_{n+1} . Soit L un langage testable par morceaux de A^* . Montrer qu'il existe $N > 0$ tel que pour tout $n \geq N$, $u_n \in L$ ou pour tout $n \geq N$, $u_n \notin L$.

Soient K et L des langages disjoints. On appelle *zigzag* entre K et L une suite de mots $(u_n)_{n \geq 0}$ telle que pour tout $n \geq 0$,

- (1) si n est pair, $u_n \in K$,
- (2) si n est impair, $u_n \in L$,
- (3) u_n est un sous-mot de u_{n+1} .

Question 12. On prend pour \mathcal{F} l'ensemble des langages testables par morceaux de A^* . Montrer que K et L sont \mathcal{F} -séparables si et seulement si il n'existe aucun zigzag infini entre K et L .

4. Approche profinie.

On dit qu'un monoïde M de \mathbf{V} *sépare* deux mots u et v s'il existe un morphisme $\varphi : A^* \rightarrow M$ tel que $\varphi(u) \neq \varphi(v)$. On fait l'hypothèse que deux mots distinct peuvent toujours être séparés par un monoïde de \mathbf{V} .

On pose, pour $u, v \in A^*$

$$r_{\mathbf{V}}(u, v) = \min\{|M| \mid M \in \mathbf{V} \text{ et } M \text{ sépare } u \text{ et } v\}$$

$$d_{\mathbf{V}}(u, v) = 2^{-r_{\mathbf{V}}(u, v)}$$

On rappelle (voir poly, Chapitre VII, section 2) que $d_{\mathbf{V}}$ est une distance ultramétrique, et que la complétion $\widehat{F}_{\mathbf{V}}(A)$ de A^* pour $d_{\mathbf{V}}$ est un monoïde compact. On note \overline{L} la clôture d'une partie L de A^* dans $\widehat{F}_{\mathbf{V}}(A)$.

Question 13. Montrer que si K et L sont \mathcal{F} -séparables, alors \overline{K} et \overline{L} sont disjoints.

Question 14. Montrer réciproquement que si \overline{K} et \overline{L} sont disjoints, alors K et L sont \mathcal{F} -séparables.

Solution

1. Generalities and examples

Question 1. If L and L^c are \mathcal{F} -separable, then there exists a language $S \in \mathcal{F}$ such that $L \subseteq S$ and $S \cap L^c = \emptyset$. Thus necessarily $S = L$ and thus $L \in \mathcal{F}$.

Question 2. Easy direction. Let S be a language of \mathcal{F} separating $\bigcup_{1 \leq i \leq n} K_i$ and $\bigcup_{1 \leq i \leq m} L_j$. Then S separates every pair K_i and L_j .

Let $S_{i,j}$ be a language of \mathcal{F} containing K_i and disjoint from L_j . We claim that the language $S = \bigcup_{1 \leq i \leq n} \bigcap_{1 \leq j \leq m} S_{i,j}$ contains $\bigcup_{1 \leq i \leq n} K_i$ and is disjoint from $\bigcup_{1 \leq j \leq m} L_j$. Indeed, we have on the one hand $K_i \subseteq S_{i,j}$ for each $j \in J$ and thus $K_i \subseteq \bigcap_{1 \leq j \leq m} S_{i,j}$. It follows that $\bigcup_{1 \leq i \leq n} K_i \subseteq S$. On the other hand, we have $S \cap (\bigcup_{1 \leq j \leq m} L_j) = \bigcup_{1 \leq j \leq m} (S \cap L_j)$. Further, one gets

$$S \cap L_k = \bigcup_{1 \leq i \leq n} \left(\bigcap_{1 \leq j \leq m} S_{i,j} \right) \cap L_k \subseteq \bigcup_{1 \leq i \leq n} (S_{i,k} \cap L_k) = \emptyset$$

which proves the claim. Since \mathcal{F} is a Boolean algebra of languages, S belongs to \mathcal{F} .

Question 3. Let L be a star-free language containing $(a^2)^*$. Since L is star-free, there exists by Schützenberger's Theorem an integer n such that $a^n \sim_L a^{n+1}$. Since $a^{2n} \in (a^2)^*$, we get $a^{2n} \in L$ and thus $a^{2n+1} \in L$. Therefore L meets $(a^2)^*a$, a contradiction. The languages $(ab)^+$ and ba^* can be separated for instance by aA^* .

Question 4. Let S be a piecewise testable language. Then there exists $n > 0$ such that S is saturated by \sim_n . Now $(ab)^n \sim_n (ba)^n$ and thus if S contains $(ab)^+$, it will contain $(ab)^n$ and hence $(ba)^n$. It follows that S cannot separate $(ab)^+$ and $(ba)^+$.

The language a^* separates $(a^2)^*$ and $(b^2)^*b$. The syntactic monoid of a^* is idempotent and commutative and hence \mathcal{J} -trivial. Thus a^* is piecewise testable. Let F be any finite set of words of odd length. Then $a^* - F$ is also piecewise testable and also separates $(a^2)^*$ and $(b^2)^*b$. Suppose there is a minimal \mathcal{F} -separator for $(a^2)^*$ and $(b^2)^*b$. Then it should be contained in all languages $a^* - F$ and hence also in their intersection, which is equal to $(a^2)^*$. But $(a^2)^*$ is not piecewise testable.

Question 5. To separate $(ab)^+$ et $(ac)^+$, it suffices to take $S = A^*bA^*$. Let $S \in \mathcal{F}$ be such that $(a(b+c))^+ \subseteq S$ and $(ba)^+ \cap S = \emptyset$. Then $ab \in S$ by the first condition and thus $ba \in S$ since S is a commutative language. This yields a contradiction since $ba \in (ba)^+$.

Question 6. Since \mathcal{F} is finite, it suffices to check for each language $S \in \mathcal{F}$ whether S separates L_1 and L_2 .


2. Pointlike sets

Question 7. Let $N \in \mathbf{V}$ and let $\tau : M \rightarrow N$ be a relational morphism. Let $n \in \tau(a)$. Since N is idempotent, $\{n\}$ is a subsemigroup of N and thus $\tau^{-1}(n)$ is a subsemigroup of M . Since $\tau^{-1}(n)$ contains a , it also contains $a^2 = 0$. It follows that $\{a, 0\} \subseteq \tau^{-1}(n)$ and thus $\{a, 0\}$ is \mathbf{V} -pointlike. Similarly, $\{b, 0\}$ is \mathbf{V} -pointlike.

Finally, let $\tau : M \rightarrow U_1$ be the relational morphism defined by $\tau(1) = \tau(b) = 1$, $\tau(a) = 0$ and $\tau(0) = \{0, 1\}$. Then $\tau^{-1}(0) = \{0, a\}$ and $\tau^{-1}(1) = \{1, b, 0\}$. Thus $\{a, b\}$ is not \mathbf{V} -pointlike.

Question 8. Let $P = \gamma(S)$. Since γ is the syntactic morphism of S , we also have $\gamma(S^c) = P^c$. Then the relations $\tau(p) = \gamma(\pi^{-1}(p)) \subseteq \gamma(S) = P$ and $\tau(q) = \gamma(\pi^{-1}(q)) \subseteq \gamma(S^c) = P^c$ show that $\tau(p)$ and $\tau(q)$ are disjoint. It follows that $\{p, q\}$ is not a \mathbf{V} -pointlike subset of M since if $\{p, q\} \subseteq \tau^{-1}(n)$, then $n \in \tau(p) \cap \tau(q)$.

Question 9. Suppose that $\{p, q\}$ is not a \mathbf{V} -pointlike subset of M . Then there is a relational morphism τ from M into a monoid N of \mathbf{V} and an element n of N such that either $p \in \tau^{-1}(n)$ and $q \notin \tau^{-1}(n)$ or $q \in \tau^{-1}(n)$ and $p \notin \tau^{-1}(n)$. Let $\tau = \beta \circ \alpha^{-1}$ be the canonical factorization of τ . Since α is surjective, there is a morphism $\delta : A^* \rightarrow R$ such that $\pi = \alpha \circ \delta$. Setting $\gamma = \beta \circ \delta$, one has $\tau = \gamma \circ \pi^{-1}$ since $\gamma \circ \pi^{-1} = \beta \circ \delta \circ \pi^{-1} = \beta \circ \delta \circ (\alpha \circ \delta)^{-1} = \beta \circ \delta \circ \delta^{-1} \circ \alpha^{-1} = \beta \circ \alpha^{-1}$.



Let $S = \gamma^{-1}(n)$. Since $N \in \mathbf{V}$, the language L belongs to \mathcal{F} . Suppose that $p \in \tau^{-1}(n)$ and $q \notin \tau^{-1}(n)$. Since $\tau^{-1} = \pi \circ \gamma^{-1}$, one has $p \in \pi(L)$ and $q \notin \pi(L)$. It follows that L contains $\pi^{-1}(p)$ and is disjoint from $\pi^{-1}(q)$. The case where $q \in \tau^{-1}(n)$ and $p \notin \tau^{-1}(n)$ is symmetrical, since then L^c contains $\pi^{-1}(p)$ and is disjoint from $\pi^{-1}(q)$. It follows that the languages $\pi^{-1}(p)$ and $\pi^{-1}(q)$ are \mathcal{F} -separable.

Question 10. Let $\pi : A^* \rightarrow M$ be a surjective morphism. Suppose that the \mathcal{F} -separation problem is decidable. Then by Question 9, one can decide whether or not $\{p, q\}$ is pointlike.

Suppose that one can decide whether a two-element set is pointlike and let K and L be two regular languages of A^* . Then there exist a finite monoid M , a surjective morphism $\pi : A^* \rightarrow M$ and two subsets P and Q of M such that $K = \pi^{-1}(P)$ and $L = \pi^{-1}(Q)$. By Question 2, K and L are \mathcal{F} -separable if and only if, for each $p \in P$ and $q \in Q$, the languages $\pi^{-1}(p)$ and $\pi^{-1}(q)$ are \mathcal{F} -separable. By Questions 8 and 9, this is equivalent to saying that $\{p, q\}$ is not pointlike. It follows that \mathcal{F} -separation is decidable.

3. Piecewise testable languages

Question 11. Let S be a piecewise testable language. Then there exists $k > 0$ such that S is saturated by \sim_k . Denote by $S_k(u)$ the set of subwords of length $\leq k$ of u . If $(u_n)_{n \geq 0}$ is a sequence of words such that, for each n , u_n is a subword of u_{n+1} , then $S_k(u_n) \subseteq S_k(u_{n+1})$ and since there are only finitely many words of length $< k$, there exists N such that for all $n \geq N$, $S_k(u_n) = S_k(u_N)$, it follows that $u_n \sim_k u_N$ and thus either for all $n > N$, $u_n \in L$ or for all $n > N$, $u_n \notin L$.

Question 12. Suppose there exists an infinite zigzag $(u_n)_{n \geq 0}$ between K and L and let S be a piecewise testable language separating K and L . Then by construction, $u_n \in S$ if n is even and $u_n \notin S$ if n is odd, a contradiction with question 11.

Conversely,

4. A profinite approach

Question 13. Suppose that K and L are separated by a language S of \mathcal{F} . Then $\overline{K} \cap \overline{L} \subseteq \overline{S} \cap \overline{S}^c$. But in the pro- \mathbf{V} topology, $\overline{S}^c = (\overline{S})^c$ and thus $\overline{S} \cap \overline{S}^c = \emptyset$. Therefore $\overline{K} \cap \overline{L} = \emptyset$.

Question 14. Suppose that $\overline{K} \cap \overline{L} = \emptyset$. Then every $u \in \overline{K}$ belongs to the open set $(\overline{L})^c$. Since the closure of the languages of \mathcal{F} form a basis of the topology of $\widehat{F}_{\mathbf{V}}(A)$, there exists a language S_u of \mathcal{F} containing u such that $\overline{S_u} \subseteq (\overline{L})^c$. Thus $\overline{K} \subseteq \bigcup_{u \in \overline{K}} \overline{S_u}$. Since \overline{K} is closed, hence compact, one can extract a finite cover $\overline{S_{u_1}}, \dots, \overline{S_{u_n}}$. Setting $S = S_{u_1} \cup \dots \cup S_{u_n}$, we get $\overline{K} \subseteq \overline{S}$, whence $K \subseteq S$ since $\overline{K} \cap A^* = K$ and $\overline{S} \cap A^* = S$. Moreover $S \subseteq \overline{S} \subseteq (\overline{L})^c \subseteq L^c$.