

Langages formels et automates – cours 6

Compléments d'expressions régulières

Catalin Dima

Compléments expressions régulières

- ▶ Expressions régulières **étendues** : inclure la complémentation dans les opérations :

$$\overline{(a + \overline{bc})^* + ac^* + a(c\overline{a^*b})}$$

- ▶ Sémantique de la nouvelle opération = complémentation :

$$|\overline{E}| = \Sigma^* \setminus |E|$$

- ▶ Donc on inclut l'intersection aussi !

- ▶ Équivalence des expressions régulières étendues avec les automates finis :

- ▶ Corollaire du théorème de Kleene ...
- ▶ ... et de la fermeture de $Rec(\Sigma)$ par complémentation.

- ▶ Exemple :

- ▶ $L_5 = \{w \in \{a, b, c\}^* \mid w \text{ ne contient pas la séquence } aab\}$.

$$L_5 = \overline{((a + b + c)^* aab (a + b + c)^*)}$$

- ▶ Ça suffit pour prouver que L_5 est reconnaissable !

Compléments expressions régulières

- ▶ Problème de *sémantique vide* :
 - ▶ Étant donnée une expression régulière étendue, décider si sa sémantique est un langage vide.
 - ▶ Algorithme : il faut convertir en automate fini.
 - ▶ Complexité **énorme** si bcp de compléments imbriqués : chaque complémentation implique une détermination !
 - ▶ Donc une explosion exponentielle de l'espace d'états !
 - ▶ On peut prouver que cette explosion exponentielle est inévitable !

Compléments expressions régulières

Et l'algorithme de test de sémantique vide pour des expressions régulières normales ?

- ▶ Trivial !
- ▶ Un peu (mais très peu !) plus compliqué si on accepte aussi \emptyset dans les expressions atomiques.
- ▶ Exemple :

$$E_1 = (a + bc^*)^* + \emptyset^* a$$

$$E_1 = a^* \emptyset + \emptyset (b + c)$$

- ▶ Idée d'algorithme :
 - ▶ Construire l'arbre syntaxique de l'expression.
 - ▶ Vérifier qu'il existe au moins un chemin pour lequel
 1. Soit le chemin contient une étoile.
 2. Soit le chemin se termine avec une expression atomique non-vide.
 - ▶ Utiliser n'importe quel parcours (prefix, infix, postfix).

Automates déterministes à partir d'expressions régulières

- ▶ On sait construire des automates (avec ε -transitions) à partir d'expressions régulières.
- ▶ Et on sait éliminer les ε -transitions et déterminer les automates finis.
- ▶ Mais peut-on construire des automates déterministes plus directement ?
- ▶ Petite idée : utiliser les *quotients* des langages :
 - ▶ $a \setminus L =$ ce qui reste à parcourir du mot, après avoir "avalé" un a .
- ▶ Il faudrait alors essayer de construire itérativement les quotients à gauche pour toutes les lettres de l'alphabet.
- ▶ Mais comment formaliser le résultat sur des expressions régulières ?

Dérivées de Brzozowski

- ▶ Les quotients gauche des expressions régulières – calculés itérativement à l'aide des “schémas”
 - ▶ Un peu comme les dérivées des fonctions.
- ▶ $\partial_a(E)$ = autre notation pour $a \setminus E$.
- ▶ Règles de calcul (définition par induction structurelle) :

$$\partial_a(a) = \varepsilon$$

$$\partial_a(E_1 + E_2) = \partial_a(E_1) + \partial_a(E_2)$$

$$\partial_a(b) = \partial_a(\varepsilon) = \emptyset$$

$$\partial_a(E_1 \cdot E_2) = \partial_a(E_1) \cdot E_2 + o(E_1) \cdot \partial_a(E_2)$$

$$\partial_a(E^*) = \partial_a(E) \cdot E^*$$

- ▶ Ici, $o(E)$ indique si ε appartient à $|E|$.
- ▶ Sa définition par induction structurelle est :

$$o(a) = \emptyset$$

$$o(E_1 + E_2) = o(E_1) + o(E_2)$$

$$o(\varepsilon) = \varepsilon$$

$$o(E_1 \cdot E_2) = o(E_1) \cdot o(E_2)$$

$$o(E^*) = \varepsilon$$

Dérivées d'une expressions régulière

- ▶ Étant donné une expression E , on construit toutes ses dérivées.
- ▶ Et toutes les dérivées des dérivées, et les dérivées de 3e ordre, de 4e ordre...
- ▶ Quand s'arrêter ?
- ▶ Formalisation

$$\mathcal{D}_0 = \{E\}$$

$$\mathcal{D}_{n+1} = \mathcal{D}_n \cup \{\partial_a(E) \mid E \in \mathcal{D}_n, a \in \Sigma\}$$

- ▶ Exemple :

$$E = (ab^* + c)^* + a^*bc^*$$

$$\mathcal{D}_1 = ? \quad \mathcal{D}_2 = ? \quad \mathcal{D}_3 = ? \dots$$

- ▶ Il faut observer que $|a^*bc^*| \subseteq |(ab^* + c)^*|$.
- ▶ ... et donc on peut s'arrêter plus tôt !
- ▶ Et en général, la suite (\mathcal{D}_n) s'arrête toujours ?...

Théorème de Brzozowski

1. Pour toute $E \in \text{RegExpr}(\Sigma)$ et $a \in \Sigma$,

$$|\partial_a(E)| = a \setminus |E| = \{w \in \Sigma^* \mid aw \in |E|\} \quad (1)$$

$$|o(E)| = \begin{cases} \varepsilon & \text{si } \varepsilon \in |E| \\ \emptyset & \text{sinon} \end{cases} \quad (2)$$

2. La suite $(\mathcal{E}_n)_{n \geq 0}$ définie comme suit :

$$\mathcal{E}_n = \{|E| \mid E \in \mathcal{D}_n\}$$

est **convergente** : il existe un n tel que $\mathcal{E}_n = \mathcal{E}_{n+1} = \mathcal{E}$.

3. La structure suivante est un automate fini **équivalent** avec l'expression donnée :

$$\mathcal{A} = (\mathcal{E}_n, \Sigma, \delta, \{|E|\}, \mathcal{E}^f)$$

$$\delta = \{|E_i| \xrightarrow{a} |E_j| \mid E_i, E_j \in \mathcal{D}_n, \partial_a(E_i) = E_j\}$$

$$\mathcal{E}^f = \{|E_i| \mid E_i \in \mathcal{D}_n, o(E_i) = \varepsilon\}$$

Le théorème de Brzozowski dans la “pratique”

Exemple pour $E = (ab^* + c)^* + a^*bc^*$

- ▶ On calcule \mathcal{D}_n itérativement.
- ▶ Mais il nous faut \mathcal{E}_n .
- ▶ Malheureusement cela impliquerait de construire des automates pour chacune des expressions de \mathcal{D}_n ...
- ▶ ... et de tester l'égalité des langages !!
- ▶ Alors on essaie de construire un automate dont les états sont étiquetés par \mathcal{D}_n , et non pas par \mathcal{E}_n .
- ▶ Exemple avec $E = (ab^* + c)^* + a^*bc^*$.
- ▶ Il nous fait toutefois des règles permettant de décider quand on ne rajoute pas de nouvel état !
- ▶ Il nous faut des **identités** sur les trois opérations $\cdot, +, *$

Algèbre de Kleene

- ▶ Est-ce qu'on peut donner un ensemble de règles sur les trois opérations \cdot , $+$, $*$?
 - ▶ On voudrait prouver que $|E_1| = |E_2|$ sans devoir construire les automates !
 - ▶ On voudrait juste modifier l'expression E_1 pour la transformer en E_2 .
- ▶ On cherche en fait des **axiomes** !
- ▶ Et on en connaît quelques-unes :
 - ▶ Associativité et commutativité de l'union.
 - ▶ Associativité de la concaténation.
 - ▶ Distributivité de \cdot par rapport à $+$.
 - ▶ Idempotence de $+$: $X + X = X$.
- ▶ Et l'étoile ?
- ▶ On a une structure algébrique nommée **algèbre de Kleene**

$$(\text{RegExpr}(\Sigma), +, \cdot, *, \emptyset, \{\varepsilon\})$$

Axiomatization de Conway

- ▶ Toute identité de type $|E_1| = |E_2|$ peut se prouver en utilisant l'ensemble d'axiomes suivant :
 1. Associativité de l'union et de la concaténation.
 2. Commutativité et idempotence de l'union.
 3. \emptyset est élément neutre pour l'union.
 4. $\{\varepsilon\}$ est élément neutre pour la concaténation.
 5. Distributivité de la concaténation par rapport à l'union.
 6. Axiomes pour l'étoile :

$$1 + X \cdot X^* \subseteq X^* \quad (3)$$

$$1 + X^* \cdot X \subseteq X^* \quad (4)$$

$$\text{si } 1 + AX \subseteq X \text{ alors } A^*X \subseteq X \quad (5)$$

$$\text{si } 1 + XA \subseteq X \text{ alors } XA^* \subseteq X \quad (6)$$

- ▶ Ça peut se traduire en algorithme.
- ▶ Mais nous on va se limiter à deviner les équivalences.
- ▶ Quelques exemples en TD.

Langages réguliers sur une seule lettre

- ▶ Qu'est-ce qu'on obtient si $\Sigma = \{a\}$?
- ▶ Peut-on décrire de manière plus simple un langage comme :

$$E = ((aa^* + aaa)^* + aa^*aa^*)^*$$

- ▶ **Théorème** : La sémantique de toute expression régulière ayant un seul atome a est un langage quasi-périodique :
 - ▶ L'ensemble des longueurs de mots du langage forme un ensemble **finalemtent périodique**.
 - ▶ C.à.d. union finie de **progressions arithmétiques** de même ratio, plus un ensemble fini de nombres.
- ▶ Pour notre cas on retrouve tous les mots d'une seule lettre :

$$|E| = |a^*|$$

- ▶ Preuve par induction :
 - ▶ Il faut prouver que l'étoile d'un langage de type quasi-périodique est aussi quasi-périodique.
 - ▶ Ce qui revient à prouver une propriété similaire sur les **ensembles de nombres naturels**.

Algèbre de Kleene sur les ensembles d'entiers

- ▶ On peut organiser $\mathcal{P}(\mathbb{N})$ comme algèbre de Kleene :

$$(\mathcal{P}(\mathbb{N}), \cup, +, *, \emptyset, \mathbf{0})$$

- ▶ L'étoile :

$$A^* = \{a_1 + \dots + a_n \mid n \geq 0, a_i \in A \text{ pour tout } 1 \leq i \leq n\}$$

- ▶ Idée de preuve : écrire comme un ensemble finalement périodique :

$$\{2, 3\}^* =? \quad \{12, 15, 21\}^* =? \quad (2^* \cup 3^*)^* =?$$

- ▶ On découvre que

$$\{a, b\}^* = F \cup \{dn + k \mid n \in \mathbb{N}\} = F \cup (\{d\}^* + \{k\})$$

où d est le **pgcd** de a et de b .

PGCD et expressions régulières sur des alphabets à une lettre

- ▶ Pourquoi a-t-on $\{a, b\}^* = F \cup (\{pgcd(a, b)\}^* + \{k\})$?
- ▶ C'est une application d'un théorème de Bézout
 - ▶ L'équation $ax + by = c$ admet des solutions si et seulement si c est un multiple du $pgcd(a, b)$.
 - ▶ Si $c > ab$ alors cette équation admet des solutions *positives*.
- ▶ Donc tout multiple du $pgcd(a, b)$ plus grand que ab appartient à $\{a, b\}^*$!
- ▶ Pour tous les autres (nombre fini), il y a certains qui le sont, certains qui ne le sont pas.
- ▶ Ceux qui le sont appartiennent au F .
- ▶ Les axiomes d'algèbre de Kleene nous assurent alors que le théorème est vrai en général :

$$\{a, b, c\}^* = (\{a, b\}^* \cup \{c\})^*$$

- ▶ Exemples :

$$\begin{aligned} |(aa)^*| &= \{a^{2n} \mid n \in \mathbb{N}\} \\ |(a^6 + a^4)^*| &= \{\varepsilon\} \cup \{a^{2n+4} \mid n \in \mathbb{N}\} \end{aligned}$$