

Linguistique computationnelle

Chapitre 3

Expressions régulières

Table des matières	
3	Expressions régulières 1
3.1	Mots, langages (formels) 1
3.1.1	Alphabet, mot, concaténation 1
3.1.2	Langage (formel) 2
3.1.3	Langage formel vs. naturel 3
3.2	Opérations sur les langages 3
3.2.1	Opérations ensemblistes 3
3.2.2	Opérations avec la concaténation 3
3.2.3	Opérations rationnelles 3
3.3	Automates et expressions rationnelles 5
3.3.1	Expressions rationnelles 5
3.3.2	Correspondance avec les automates 7
3.4	Le langage des expressions régulières 11
3.4.1	Version de base 11
3.4.2	Extentions : principes 11
3.4.3	Langage(s) étendu(s) 11

3.3 Automates et expressions rationnelles

3.3.1 Expressions rationnelles

Les opérations rationnelles peuvent être utilisées pour décrire des langages quelconques :

- $\{au, le, par, un\}.\{_.\}\{matin, soir\} = L_1$ ($\Sigma = \{a, b, c, \dots, z\}$)
- $\{1, 2, \dots, 9\}.\{0, 1, 2, \dots, 9\}.\left(\{,\}.\{0, 1, 2, \dots, 9\}^* \cup \{\epsilon\}\right) = L_2$ ($\Sigma = \{0, 1, 2, \dots, 9, _.\}$)
- $\{aa\}.\left(\{b\}.\{b\} \cup \{cc\}\right)^*$ ($\Sigma = \{a, b, c\}$)
- $\{aa\}.\left(\{b\}^* \cup \{cc\}\right) = L_4$ ($\Sigma = \{a, b, c\}$)



$$L_4 = \{aa, aab, aabb, \dots, aacc\}$$

$$L_1 = \{au_matin, le_soir, \dots, le_matin, par_soir, par_matin, un_soir, un_matin, au_soir\}$$

$$L_2 = \{2, 20, 13527, 97, \dots\}$$

$$\{,\}.\{0, 1, \dots, 9\}^* = \{, , , 3, , 7, , 12345, , 2222, \dots, etc\}$$

$$\{1, 2, \dots, 9\}.\{0, 1, \dots, 9\} = \{10, 11, 19, 99, 9, \dots\}$$

En particulier, on peut construire des expressions en n'utilisant que des langages choisis, qu'on peut appeler **la base** :

- $(\{0\} \cup \{1\} \cup \dots \cup \{9\}) \cdot (\{0\} \cup \{1\} \cup \dots \cup \{9\})^*$

- $\{a\} \cdot \{a\} \cdot (\{b\}^* \cup \{c\} \cdot \{c\})$

$$\{\epsilon, b, bb, bbb, \dots\} \cup \{cc\}$$

$$\{9, 90, 987, \dots, 07\}$$

$$\{0\} \cup \{1\} \cup \{2\} = \{0, 1, 2\}$$

exclut
aabcc
bac

$\{aabb, aacc, aab, \dots\}$
aa

$$\{aa, b\} \cdot \{cc, abc\}^*$$

langages
Singleton

(avec une seule
lettre.

Pour $X = \{a, b, c, d\}$, On peut définir $X^* = (\{a\} \cup \{b\} \cup \{c\} \cup \{d\})^*$

X^* : tous les mots qu'on peut former sur l'alphabet X

Notation simplifiée :

- {a} sera simplement noté a
- {ε} sera simplement noté ε
- la réunion ∪ se notée |
- le point de la concaténation sera ignoré

{a} {b}

$$(b|aa)^*ab^* = (\underbrace{\{b\} \cup \{a\} \cdot \{a\}})^* \cdot \{a\} \cdot \{b\}^*$$

$$ab^* \neq (ab)^*$$

$$2 \times 2 \geq 4$$

$$\{a, b\} \cdot \{b, c\} = \{ab, ac, bb, bc\}$$


$$\{a\} \cdot \{b\} = \{ab\}$$

$$\{a, b, c\} \cup \{e, f\} = \{a, b, c, e, f\}$$

$$\{a\} \cup \{b\} = \{a, b\}$$


3.3.2 Correspondance avec les automates

Résultat principal




Correspondance : exemples



- (1) a. $(a|b)^*$
- b. $a(a|b)^*$
- c. $(b|ab)^*(a|\epsilon)$
- d. $a^*|b^*$
- e. $(aa|b)^*$
- f. $(ab^*a|b)^*$



~~$(aa|b)$~~




~~$(aa|b)^*$~~





\equiv

$ba \notin \mathcal{L}$
 $aaa \notin \mathcal{L}$
 $bbb \in \mathcal{L}$



Principe général



Elimination des ε -transitions $(a|b) \cdot c^*$ 