

Chapitre 4

Langage

1 Généralités sur les langages

1.1 Un peu de vocabulaire.

Définition 1 :

- Un **alphabet** est un ensemble fini ; ces éléments sont des **lettres**.
- Un **mot** sur l'alphabet A est une suite finie de lettres de A : $w = a_1a_2\dots a_n$.
- La **longueur du mot** précédent, notée $|w|$ est n (nombre de lettres).
- On note $|w|_a$ le nombre d'occurrences de la lettre a dans w . (on a donc $|w| = \sum_{a \in A} |w|_a$)
- On définit un **mot vide** noté généralement ϵ , constitué d'aucune lettre. Sa longueur est nulle.
- L'ensemble des mots de longueur n est noté A^n ; l'ensemble des mots est noté A^* . L'ensemble des mots non vides est noté A^+ .
- On définit la concaténation de deux mots $w_1 = a_1a_2\dots a_n$ et $w_2 = b_1b_2\dots b_m$ par $w_1.w_2 = a_1a_2\dots a_nb_1b_2\dots b_m$ de sorte que $|w_1.w_2| = |w_1| + |w_2|$.
- a^n désigne la concaténation de n lettres a (si $n = 0$, alors $a^0 = \epsilon$).
- Par convention, $\epsilon.w = w.\epsilon = w$, de sorte que \cdot définit sur A une loi de composition interne associative, non commutative (sauf si A est un singleton), de neutre ϵ . Ainsi, (A^*, \cdot) constitue un monoïde. Une autre convention consiste à confondre une lettre et le mot constitué uniquement de cette lettre.
- Un langage sur A est une partie de A^* .
- Si $w = a_1a_2\dots a_n$, les **préfixes**(resp. **suffixes**) de w sont les mots de la forme $a_1a_2\dots a_k$ (resp. $a_ka_2\dots a_n$), avec $1 \leq k \leq n$. De plus, par convention, ϵ est préfixe et suffixe de tout mot. Un préfixe (resp. suffixe)propre de w est un préfixe (resp. suffixe) distinct de ϵ .
- Un **facteur** de $w = a_1a_2\dots a_n$ est un mot de la forme $a_i\dots a_j$, avec $1 \leq i \leq j \leq n$. Un **sous-mot** est un mot de la forme $a_{i_1}\dots a_{i_k}$, avec $1 \leq i_1 < \dots < i_k \leq n$. Ici encore, ϵ est un facteur et un sous-mot de tout mot.
- Le **miroir** de $w = a_1a_2\dots a_n$ est $w' = a_n\dots a_1$. Si $w = w'$, on dit que w est un palindrome.

1.2 Propriétés.

Propriété 1 :

▮ $\forall u, v, x, y \in A^*$, $uv = xy \Rightarrow \exists t \in A^*$ tel que soit $u = xt$ et $tv = y$, soit $x = ut$ et $v = ty$

Preuve :

Théorème 1 :

▮ Si $xy = yz$ avec $x \neq \epsilon$, alors $\exists u, v \in A^*$ et un entier $k \geq 0$ tel que :

$$x = uv \quad , \quad y = (uv)^k u = u(vu)^k \quad , \quad z = vu$$

Preuve :

Théorème 2 :

▮ Si $xy = yx$, avec $x \neq \epsilon$, et $y \neq \epsilon$ alors $\exists u \in A^*$ et deux entiers i, j tels que $x = u^i$, $y = u^j$.

Preuve :

2 Opérations sur les langages .

Les langages sur A étant des parties de A^* , on dispose naturellement des notions de réunion, d'intersection , de différence et du complémentaire de langages.

$$L_1 \cup L_2 = \{w \in A^* | w \in L_1 \text{ ou } w \in L_2\}$$

$$L_1 \cap L_2 = \{w \in A^* | w \in L_1 \text{ et } w \in L_2\}$$

$$\overline{L_1} = \{w \in A^* | w \notin L_1\}$$

On peut de plus définir la concaténation (ou le produit) de deux langages L_1 et L_2 par :

$$L_1 L_2 = \{w_1 w_2 \in A^* | w_1 \in L_1 \text{ et } w_2 \in L_2\}$$

On définit alors de façon naturelle L^n comme l'ensemble des mots constitués de n mots de L concaténés :

$$L^0 = \{\epsilon\}$$

$$\forall n \in \mathbb{N} \quad , \quad L^{n+1} = L^n . L$$

Définition 2 :

La fermeture de Kleene (ou **itération** ou encore **étoile**) d'un langage L est la réunion des L_n , pour $n \in \mathbb{N}$. Elle est notée L^* :

$$L^* = \bigcup_{n \in \mathbb{N}} L^n$$

elle contient toujours le mot vide.

L^+ désigne la réunion des L^n pour $n \geq 1$:

$$L^+ = \bigcup_{n \in \mathbb{N}^*} L^n$$

Ce langage contient le mot vide si et seulement si $\epsilon \in L$. On a $L^+ = L.L^*$.

Exercice 1: Lemme d'Arden.

Soient A et B des langages (avec $\epsilon \notin A$) sur l'alphabet Σ .

Montrer que l'équation de langage suivante :

$$L = A.L \cup B$$

admet pour unique solution le langage $L = A^*B$.

3 Langages et expressions rationnelles .

3.1 Langage rationnel :

Définition 3 :

Soit l'alphabet A . Les langages rationnels sur A sont définis inductivement par :

- $\{\epsilon\}$ et \emptyset sont des langages rationnels.
- $\forall a \in A, \{a\}$ est un langage rationnel.
- Si L_1 et L_2 sont des langages rationnels, alors $L_1 \cup L_2$ et $L_1.L_2$ également.
- Si L est rationnel, alors L^* l'est également.

Remarques :

- Tous les langages finis sont rationnels, puisqu'ils se déduisent des singletons par un nombre fini d'application des opérations d'union et de concaténation.
- Par définition, l'ensemble des langages rationnels est clos pour les trois opérations rationnelles. (on dit qu'il est rationnellement clos.)
- La famille des langages rationnels correspond précisément au plus petit ensemble de langages qui contient tous les langages finis, et est rationnellement clos.

3.2 Expression rationnelle (ou régulière) :

Définition 4 :

L'ensemble E des expressions rationnelles sur un alphabet A est le plus petit ensemble tel que :

- E contient les éléments de A , ainsi que deux éléments distincts des précédents ϵ et \emptyset .
- Si e_1 et e_2 sont deux éléments de E , alors $e_1 + e_2$ et $e_1.e_2$ également.
- Si e est un élément de E , alors e^* est un élément de E .

Remarques :

- On note parfois $e_1|e_2$ à la place de $e_1 + e_2$.
- Cette définition permet les preuves par induction : pour montrer une propriété $P(e)$ pour toute expression e , il suffit d'établir $P(\emptyset)$, $P(\epsilon)$, $P(a)$ pour tout $a \in A$, puis de montrer que si $P(e_1)$ et $P(e_2)$ sont vérifiées, alors $P(e_1 + e_2)$, $P(e_1.e_2)$ et $P(e_1^*)$ également.

Définition 5 :

On définit de façon inductive le langage associé à une expression rationnelle e , noté $L(e)$:

- $L(\epsilon) = \{\epsilon\}$; $L(\emptyset) = \emptyset$; $L(a) = \{a\}$, $\forall a \in A$.
- $L(e_1 + e_2) = L(e_1) \cup L(e_2)$.
- $L(e_1.e_2) = L(e_1).L(e_2)$.
- $L(e^*) = L(e)^*$

Définition 6 :

Un langage est dit rationnel si c'est le langage associé à une expression rationnelle. On note $\text{Rat}(A)$ l'ensemble des langages rationnels : $\text{Rat}(A) \subset \mathcal{P}(A^*)$.

3.3 Équivalence et réduction :**Définition 7 :**

Deux expressions rationnelles sont équivalentes si elles dénotent le même langage.

Exemple d'expressions équivalentes

$\emptyset a = a\emptyset = \emptyset$	$\epsilon a = a\epsilon = a$
$\emptyset^* = \epsilon$	$\epsilon^* = \epsilon$
$a + b = b + a$	$a + \emptyset = a$
$a + a = a$	$a^* = (a^*)^*$
$c(a + b) = ca + cb$	$(a + b)c = ac + bc$
$(ab)^*a = a(ba)^*$	
$(a + b)^* = a^*(a + b)^*$	$(a + b)^* = (a^* + b)^*$
$(a + b)^* = (a^*b^*)^*$	$(a + b)^* = (a^*b)^*a^*$

Exercice 2: Soit $A = \{a, b\}$.

1. Montrer que le langage formé des mots comportant le facteur ab est rationnel.
2. Montrer que le langage formé des mots ne comportant pas le facteur ab est rationnel.
3. Montrer que le langage formé des mots comportant le facteur ab mais pas le facteur aa est rationnel.

Exercice 3 : Soit A un alphabet, L un langage et $u \in A^*$. On définit le quotient (ou résiduel) gauche de L par u par :

$$u^{-1}L = \{v \in A^* | uv \in L\}$$

Soit $a \in A$ une lettre et soient K et L deux langages.

1. Montrer que :

$$a^{-1}(K \cup L) = a^{-1}K \cup a^{-1}L$$

2. Montrer que :

$$a^{-1}(KL) = \begin{cases} (a^{-1}K)L & \text{si } \epsilon \notin K \\ (a^{-1}K)L \cup a^{-1}L & \text{si } \epsilon \in K \end{cases}$$

3. Montrer que :

$$a^{-1}L^* = (a^{-1}L)L^*$$

4. En déduire que si L est un langage rationnel alors $a^{-1}L$ est aussi un langage rationnel.

5. Montrer que si L est un langage rationnel et si $u \in A^*$ alors $u^{-1}L$ est aussi un langage rationnel.

Exercice 4 : On considère l'alphabet $\Sigma = a, b$. On note L_1 le langage des mots ayant un nombre pair de b et L_2 le langage des mots ayant un nombre impair de b .

1. Justifier que l'on a les relations :

$$L_1 = aL_1 + bL_2 + \epsilon$$

$$L_2 = aL_2 + bL_1$$

2. Résoudre le système à l'aide du lemme d'Arden.

4 Langages locaux .

Définition 8 :

On considère un langage L sur un alphabet A . On définit :

- $P(L) = \{a \in A \mid a.A^* \cap L \neq \emptyset\} = \{a \in A \mid \exists u \in A^*, a.u \in L\}$
 $P(L)$ correspond à l'ensemble des premières lettres des mots de L .
- $S(L) = \{a \in A \mid A^*.a \cap L \neq \emptyset\} = \{a \in A \mid \exists u \in A^*, u.a \in L\}$
 $S(L)$ correspond à l'ensemble des dernières lettres des mots de L .
- $F(L) = \{(a, b) \in A^2 \mid A^*.ab.A^* \cap L \neq \emptyset\} = \{(a, b) \in A^2 \mid \exists (u, v) \in (A^*)^2, u.a.b.v \in L\}$
 $F(L)$ correspond à l'ensemble des facteurs de 2 lettres des mots de L .
- $N(L) = \{(a, b) \in A^2 \mid A^*.ab.A^* \cap L = \emptyset\} = \{(a, b) \in A^2 \mid \exists (u, v) \in (A^*)^2, u.a.b.v \notin L\}$
 $N(L)$ correspond à l'ensemble des mots de 2 lettres non facteurs des mots de L .

Exemple 1 :

Pour $L = L(a^*bb^*)$, sur l'alphabet $A = \{a, b\}$, on a :

- | | |
|---|--|
| <ul style="list-style-type: none"> • $P(L) = \{a, b\}$ • $S(L) = \{b\}$ | <ul style="list-style-type: none"> • $F(L) = \{aa, ab, bb\}$ • $N(L) = \{ba\}$ |
|---|--|

Définition 9 :

Un langage L sur un alphabet A est local s'il existe deux parties P et S de A et une partie N de A^2 telles que w est un mot de L si et seulement si :

- la première lettre de w est dans P ;
- la dernière lettre de w est dans S ;
- Aucun facteur de longueur 2 de w n'est dans N .

On a alors :

$$L \setminus \{\epsilon\} = (PA^* \cap A^*S) \setminus (A^*NA^*)$$

Exemple 2 :

Sur l'alphabet $A = \{a, b\}$, les langages suivants sont locaux :

- $L = L(ab)$ car $ab = aA^* \cap A^*b \setminus A^*\{aa, bb, ba\}A^*$.
- $L = L((ab)^*)$ car $(ab)^+ = aA^* \cap A^*b \setminus A^*\{aa, bb\}A^*$.
- $L = L((a)^*)$ car $a^+ = aA^* \cap A^*a \setminus A^*\{ab, ba, bb\}A^*$.

Exercice 5: Montrer que, sur l'alphabet $A = \{a, b\}$, les langages suivants :

- $L_1 = L((a)^*) \cup L((ab)^*) = L(a^* + (ab)^*)$.
- $L_2 = L((a)^*).L((ab)^*) = L((a)^*. (ab)^*)$.

ne sont pas locaux.

Théorème 3 :

■ L'intersection de deux langages locaux est un langage local.

Preuve :

Théorème 4 :

■ Si L_1 et L_2 sont deux langages locaux définis sur des alphabets disjoints, alors $L_1 \cup L_2$ est encore un langage local.

Preuve :

Théorème 5 :

Si L_1 et L_2 sont deux langages locaux définis sur des alphabets disjoints, alors $L_1.L_2$ est encore un langage local.

Preuve :

Théorème 6 :

La fermeture de Kleene L^* d'un langage local L est aussi un langage local.

Preuve :

5 Expressions rationnelles linéaires.

Définition 10 :

Une expression rationnelle e est dite linéaire lorsque tout caractère de A apparaît au plus une fois dans e :

$$\forall a \in A \quad |e|_a \leq 1$$

Exemple 3 :

1. $e_1 = ab$ est une expression rationnelle linéaire.
2. $e_2 = (ab)^*$ est une expression rationnelle linéaire.
3. $e_3 = (ab)^*a$ n'est pas une expression rationnelle linéaire.

Théorème 7 :

Toute expression rationnelle linéaire dénote un langage local.

Preuve :