

## I Alphabet et mot

### Définition : Alphabet

---



---

### Définition : Mot

---



---



---

Le mot vide (contenant aucune lettre) est noté  $\varepsilon$ .

$\Sigma^*$  est l'ensemble des mots sur  $\Sigma$ .  $\Sigma^+ = \Sigma^* \setminus \{\varepsilon\}$ .  $\Sigma^n$  est l'ensemble des mots de longueur  $n$  sur  $\Sigma$ .

### Définition : Égalité de mots

Deux mots  $u = u_1 \dots u_n$  et  $v = v_1 \dots v_p$  sur le même alphabet  $\Sigma$  sont égaux s'ils ont la même longueur ( $n = p$ ) et si pour tout  $i \in \{1, \dots, n\}$ ,  $u_i = v_i$ .

### Définition : Concaténation et puissance

---



---



---



---

### Exercice 1.

Soient  $\Sigma$  un alphabet,  $a, b \in \Sigma$  et  $u \in \Sigma^*$ . On suppose  $au = ub$ .

Montrer que  $a = b$  et qu'il existe  $k \in \mathbb{N}$  tel que  $u = a^k$ .

---



---



---



---



---

### Définition : Préfixe, suffixe, facteur, sous-mot

- $u$  est un préfixe de  $m$  s'il existe un mot  $v$  tel que  $m = uv$ .
- $u$  est un suffixe de  $m$  s'il existe un mot  $v$  tel que  $m = vu$ .
- $u$  est un facteur (*substring* en anglais) de  $m$  s'il existe des mots  $v, w$  tels que  $m = vuw$ .
- $u$  est un sous-mot (*subsequence* en anglais) de  $m$  si  $u$  est une sous-suite (ou : suite extraite) de  $m$ .

Exemple : abc est un sous-mot de *aabacb*, mais pas un facteur.

## II Langage

### Définition : Langage

---

---

Exemples :

1. L'ensemble  $L_1$  des mots du dictionnaire français sur  $\Sigma = \{a, b, \dots, z\}$ .
2. L'ensemble  $L_2$  des formules arithmétiques sur  $\Sigma = \{0, \dots, 9, +, -, /, *\}$ .
3. L'ensemble  $L_3$  des programmes OCaml sur  $\Sigma = \{a, \dots, z, !, <, >, \dots\}$ .
4. L'ensemble  $L_4$  des ADN sur  $\Sigma = \{A, C, G, T\}$ .

### Définition : Concaténation

---

---

### Définition : Puissance

---

---

---

Exemple :  $\Sigma^n$  est l'ensemble des mots de longueur  $n$  sur l'alphabet  $\Sigma$ .

### Exercice 2.

Soit  $L$  un langage.

1. À quelle condition a-t-on  $L \subseteq L^2$  ?
2. Quel lien a-t-on entre  $L^2$  et  $\{u^2 \mid u \in L\}$  ?

---

---

---

---

---

### Définition : Étoile de Kleene

---

---

Remarque :  $L^*$  contient toujours  $\varepsilon$  car  $L^0 = \{\varepsilon\}$ .

### Exercice 3.

Montrer que  $(L^*)^* = L^*$ .

---

---

---

### III Langages réguliers

**Définition : Langage régulier (ou : langage rationnel)**

Définition inductive équivalente :

**Propriété**

- Tout langage fini est régulier
- $L_1$  et  $L_2$  réguliers  $\implies L_1 \cup L_2$  régulier
- $L_1$  et  $L_2$  réguliers  $\implies L_1 L_2$  régulier
- $L$  régulier  $\implies L^*$  régulier

Par récurrence immédiate, si  $L_1, \dots, L_n$  sont réguliers alors  $L_1 \cup \dots \cup L_n$  et  $L_1 L_2 \dots L_n$  sont réguliers.

Attention : une union infinie de langages réguliers n'est pas forcément régulière.

Exemples :

1. Soit  $m$  un mot. Alors  $\{m\}$  est fini donc est un langage régulier, qu'on note aussi  $m$  par abus de langage.
2.  $\Sigma$  est fini donc est régulier.  $\Sigma^*$  est l'étoile d'un langage régulier donc est régulier.
3. Soit  $m$  un mot. L'ensemble des mots ayant comme facteur  $m$  est égal à  $\Sigma^* m \Sigma^*$  donc est un langage régulier.
4. Soit  $m = m_1 \dots m_n$  un mot. L'ensemble des mots ayant comme sous-mot  $m$  est égal à  $\Sigma^* m_1 \Sigma^* m_2 \dots \Sigma^* m_n \Sigma^*$  donc est un langage régulier.

#### Exercice 4.

Montrer que les langages suivants sont réguliers sur  $\Sigma = \{a, b\}$  :

1. Mots commençants par  $a$  : \_\_\_\_\_
2. Mots commençants par  $a$  et finissant par  $b$  : \_\_\_\_\_
3. Mots de taille paire : \_\_\_\_\_
4. Mots de taille impaire : \_\_\_\_\_

### IV Expressions régulières

Les expressions régulières sont une notation plus concise pour représenter un langage régulier :

**Définition : Expression régulière (ou : expression rationnelle)**

L'ensemble des expressions régulières sur un alphabet  $\Sigma$  est le plus petit langage  $\mathcal{R}$  sur  $\Sigma \cup \{\emptyset, \varepsilon, |, *, (, )\}$  vérifiant :

- $\forall a \in \Sigma, a \in \mathcal{R}$
- $\emptyset \in \mathcal{R}, \varepsilon \in \mathcal{R}$
- $\forall e_1, e_2 \in \mathcal{R}, (e_1 | e_2) \in \mathcal{R}$  et  $(e_1 e_2) \in \mathcal{R}$
- $\forall e \in \mathcal{R}, e^* \in \mathcal{R}$

On peut les représenter informatiquement par le type OCaml :

```

type 'a regexp =
| Vide | Epsilon | L of 'a (* L a est la lettre a *)
| Union of 'a regexp * 'a regexp
| Concat of 'a regexp * 'a regexp
| Etoile of 'a regexp

```

### Définition : Langage d'une expression régulière

Si  $e$  est une expression régulière, on définit le langage  $L(e)$  récursivement :

- $L(a) = \{a\}$  si  $a \in \Sigma$
- $L(\emptyset) = \emptyset$ ,  $L(\varepsilon) = \{\varepsilon\}$
- $L(e|e') = L(e) \cup L(e')$
- $L(ee') = L(e)L(e')$
- $L(e^*) = L(e)^*$

Remarques :

- Par abus de langage, on confond souvent  $e$  et  $L(e)$ .
- Les expressions rationnelles sont une façon plus pratique de décrire les langages réguliers, en utilisant  $|$  au lieu de  $\cup$  et en omettant les parenthèses.

### Théorème

Soit  $L$  un langage.

$L$  est régulier si et seulement si il existe une expression régulière  $e$  telle que  $L = L(e)$ .

Exemples :

- $(a|b)^*$  : ensemble de tous les mots ( $= \Sigma^*$ ).
- $(a|b)^*bb$  : mots finissant par  $bb$ .

### Exercice 5.

Donner une expression régulière pour les langages suivants, sur  $\Sigma = \{a, b\}$  :

1. Mots contenant au plus un  $a$  : \_\_\_\_\_
2. Mots de taille  $n \equiv 1 \pmod 3$  : \_\_\_\_\_
3. Mots contenant un nombre pair de  $a$  : \_\_\_\_\_
4. Mots contenant un nombre impair de  $a$  : \_\_\_\_\_
5. Écritures en base 2 des entiers divisibles par 4 : \_\_\_\_\_

## V Induction structurelle

### Théorème : Induction structurelle sur les langages réguliers

Soit  $\mathcal{P}(L)$  une propriété sur les langages réguliers  $L$  telle que :

- $\mathcal{P}(L)$  est vraie pour les langages  $L$  finis (cas de base)
- $\mathcal{P}(L_1) \wedge \mathcal{P}(L_2) \implies \mathcal{P}(L_1L_2)$
- $\mathcal{P}(L_1) \wedge \mathcal{P}(L_2) \implies \mathcal{P}(L_1 \cup L_2)$
- $\mathcal{P}(L) \implies \mathcal{P}(L^*)$

Alors  $\mathcal{P}(L)$  est vraie pour tout langage régulier  $L$ .

Preuve : \_\_\_\_\_

De même pour les expressions régulières :

**Théorème : Induction structurelle sur les expressions régulières**

Soit  $\mathcal{P}(e)$  une propriété sur les expressions régulières telle que :

- $\mathcal{P}(\emptyset), \mathcal{P}(\varepsilon)$  sont vraies (cas de base)
- $\mathcal{P}(a)$  est vraie pour  $a \in \Sigma$  (cas de base)
- $\mathcal{P}(e_1) \wedge \mathcal{P}(e_2) \implies \mathcal{P}(e_1e_2)$
- $\mathcal{P}(e_1) \wedge \mathcal{P}(e_2) \implies \mathcal{P}(e_1 \cup e_2)$
- $\mathcal{P}(e) \implies \mathcal{P}(e^*)$

Alors  $\mathcal{P}(e)$  est vraie pour toute expression régulière  $e$ .

**Exercice 6.**

Si  $m = m_1 \dots m_n$  est un mot, on définit son miroir  $\tilde{m} = m_n \dots m_1$ .

Si  $L$  est un langage, on définit son miroir  $\tilde{L} = \{\tilde{m} \mid m \in L\}$ .

1. Donner une expression régulière du miroir de  $a(a|b)^*b$ .
2. Soit  $e$  une expression régulière de langage  $L$ . Montrer que  $\tilde{L}$  est régulier.
3. Écrire une fonction Caml `miroir` : `'a regexp -> 'a regexp` renvoyant le miroir d'une expression régulière.

---

---

---

---

---

---

---

---

---

---