

# AU-DELÀ DES LANGAGES RÉGULIERS

---

À la fin de ce chapitre, je sais :

- ☞ expliquer les limites des langages réguliers
- ☞ montrer qu'un langage n'est pas régulier

## A Limites des expressions régulières

Les langages réguliers permettent de reconnaître un motif dans un texte. Néanmoins, ils ne permettent pas de mettre un sens sur le motif reconnu : celui-ci est reconnu par l'automate mais en quoi est-il différent d'un autre mot reconnu par cet automate? Par exemple, on peut reconnaître les mots qui se terminent par *tion* mais on ne saura pas faire la différence sémantique entre *révolution* et *abstention*.

Un autre exemple classique est l'interprétation des expressions arithmétiques : comment comprendre que  $a \times b - c$  se calcule  $(a \times b) - c$  et pas  $a \times (b - c)$ . Les deux motifs sont des expressions arithmétiques valides mais elle ne s'interprètent pas de la même manière. C'est là une des limites des langages réguliers : une fois motif reconnu, on ne peut pas l'interpréter. Pour la dépasser, il faut utiliser les notions de grammaires --> HORS PROGRAMME.

Une autre question se pose : comment savoir si un langage est régulier sans pour autant exhiber un automate? Comment caractériser formellement un langage régulier?

## B Caractériser un langage régulier

**Théorème 1 — Lemme de l'étoile.** Pour tout langage **régulier**  $\mathcal{L}$  sur une alphabet  $\Sigma$ , on a :

$$\exists n \geq 1, \forall w \in \mathcal{L}, |w| \geq n \Rightarrow \exists x, y, z \in \Sigma^*, w = xyz \wedge (y \neq \epsilon \wedge |xy| \leq n \wedge \mathcal{L}_{ER}(xy^*z) \subseteq \mathcal{L}) \quad (1)$$

*Démonstration.* Soit  $\mathcal{L}$  un langage régulier sur un alphabet  $\Sigma$ . D'après le théorème de Kleene, il existe un automate fini  $\mathcal{A}$  à  $n$  états qui reconnaît  $\mathcal{L}$ . Soit  $w$  un mot reconnu par l'automate  $\mathcal{A}$  à  $n$  états de longueur  $m$ . Il existe un chemin dans  $\mathcal{A}$  qui part de l'état initial  $q_0$  et s'achève sur un état accepteur  $q_m$ .

$$q_0 \xrightarrow{a_1} q_1 \xrightarrow{a_2} \dots \xrightarrow{a_m} q_m$$

En numérotant de manière incrémentale les états de 0 à  $m$ , on a nécessairement  $m > n$ . D'après le principe des tiroirs, comme l'automate ne possède que  $n$  états, ce chemin repasse par certains états. Prenons le premier état par lequel le chemin repasse et notons le  $i$ . Il existe donc deux entiers  $i$  et  $j$  tels que  $0 < i < j \leq n < m$  et  $q_i = q_j$ , c'est-à-dire il existe un cycle de longueur  $j - i$  sur le chemin. Comme il s'agit du premier état par lequel on repasse, les états  $q_0$  jusqu'à  $q_{j-1}$  sont tous distincts.

On choisit alors de poser  $x = a_1 \dots a_{i-1}$ ,  $y = a_i \dots a_{j-1}$  et  $z = a_j \dots a_m$ . On remarque que  $w = xyz$  et que  $x$  et  $xy$  vérifient les propriétés du lemme de l'étoile car  $y$  n'est pas vide et  $|xy| \leq n$ . Il reste à montrer que  $xy^*z \subseteq \mathcal{L}$ . Comme le chemin reconnaissant  $y$  est un cycle (cf. figure 1), on peut le parcourir autant de fois que l'on veut, 0 ou  $k$  fois, le mot sera toujours reconnu par l'automate. ■




FIGURE 1 – Illustration du lemme de l'étoile : si le nombre de lettres d'un mot reconnu  $w$  est plus grand que le nombre d'états de l'automate  $n$ , alors il existe une boucle sur laquelle on peut itérer.

**Théorème 2 — Principes des tiroirs.** Si  $n + 1$  éléments doivent être placés dans  $n$  ensembles, alors il existe au moins un ensemble qui contient au moins 2 éléments. Autrement dit, si  $E$  et  $F$  sont deux ensembles finis tels que  $|E| > |F|$ , alors il n'existe aucune application injective de  $E$  dans  $F$ .




FIGURE 2 – Illustration du principe des tiroirs : on ne peut pas ranger les éléments de  $E$  dans les tiroirs de  $F$  sans en mettre deux dans un tiroir.

**R** Le lemme de l'étoile est parfois appelé le lemme de l'itération car on peut itérer autant de fois que l'on veut  $y$ .

 **Vocabulary 1 — Pumping lemma**  $\leftrightarrow$  Lemme de l'étoile

**R** Il faut remarquer que le lemme de l'étoile peut être vérifié par un langage non régulier : il s'agit d'une condition **nécessaire pour être régulier mais pas suffisante**. C'est pourquoi, la plupart du temps, on utilise le lemme de l'étoile dans sa forme contraposée pour montrer qu'un langage n'est pas régulier : **s'il ne le vérifie pas, il n'est pas régulier**.

## C Les langages des puissances

■ **Définition 1 — Langage des puissances.** On appelle langage des puissances le langage défini par :

$$\mathcal{L}_p = \{a^n b^n, n \in \mathbb{N}\} \quad (2)$$

**Théorème 3 — Le langage des puissances n'est pas régulier.**

*Démonstration.* Par l'absurde en utilisant le lemme de l'étoile.

Supposons que  $\mathcal{L}_p$  soit régulier. Alors il vérifie le lemme de l'étoile. **Soit  $\mathcal{A}$  un automate à  $n$  état qui reconnaît  $\mathcal{L}$ .** Considérons le mot  $w = a^n b^n \in \mathcal{L}_p$ . On a bien  $|w| = 2n \geq n$ . On peut donc appliquer le lemme de l'étoile à  $w$ .

D'après ce lemme, il existe une décomposition de  $w$  en  $xyz$  qui vérifie  $|xy| \leq n$  et  $y \neq \epsilon$ . Soit  $i$  et  $j$  deux entiers naturels tels que  $i + j \leq n$  et  $j > 0$ . Cette décomposition de  $w$  est nécessairement de la forme générale  $w = a^i a^j a^{n-i-j} b^n = xyz$ , avec  $x = a^i$ ,  $y = a^j$  et  $z = a^{n-i-j} b^n$ .

Les conditions du lemme sont vérifiées et il est donc possible d'itérer sur  $y$  : un tel mot appartient toujours au langage. Donc le mot  $xy^2z = a^i a^{2j} z = a^i a^{2j} a^{n-i-j} b^n$  devrait appartenir à  $\mathcal{L}_p$ . Or ce n'est manifestement pas le cas car  $i + 2j + n - i - j = n + j > n$  car  $j > 0$ . C'est pourquoi  $\mathcal{L}_p$  n'est pas un langage régulier. ■

Ⓜ Le théorème 3 un résultat théorique important à connaître car :

- on peut s'en servir pour démontrer la non régularité d'autres langages en utilisant la stabilité de l'intersection pour les langages réguliers.
- la démonstration est canonique, c'est-à-dire typique de l'utilisation du lemme de l'étoile.