

Automate et langage régulier

Romann Szczepaniak

November 26, 2025

1 Introduction

Une expression régulière est une contrainte

1.1 Vocabulaire

1. Un alphabet : un ensemble fini de symboles, par exemple $\Sigma = \{0, 1\}$ ou $\{a, b, c\}$. Σ définit un alphabet quelconque
2. Un mot : une séquence finie de lettres sur un alphabet Σ . On peut le voir comme :
 $\phi : \{0, \dots, n-1\} \mapsto \Sigma$ pour un mot de taille n
Si u est un mot sur Σ de taille $n > 3$. Alors $u[3]$ est sa 4e lettre

1.2 Opération sur les mots

La concaténation

Exemple 1 (Exemple). *En Python, si on écrit "poulet" + "roti", on obtient "pouletroti"*

Soient u, v deux mots sur l'alphabet Σ , on note $u.v$ la concaténation de u et v , et on va appeler $w = u.v$ un mot tel que :
$$\begin{cases} w[i] = u[i] & \text{si } i < \|u\| \\ w[i] = v[i - n] & \text{sinon} \end{cases}$$

Itération

Pour u un mot sur Σ , on note $u^2 = u.u$. Par récurrence, on note :
$$\begin{cases} u^{k+1} = u^k \cdot u \\ u^0 = \varepsilon \end{cases}$$

Avec $\varepsilon : f : \emptyset \mapsto \Sigma$

Et on a la propriété suivante : $\varepsilon.u = u.\varepsilon = u$ avec u un mot de Σ

En python, on a $u+u = u*2, \dots$

Associativité

Soient u, v, w trois mots sur un alphabet Σ . On a

$$(u.v).w = u.(v.w).$$

Code Python

```
1 def f(u : str, v : str, w : str):
2     if (u + v) + w != u + (v + w):
3         raise ValueError(_)
```

Preuve. Hypothèse de récurrence

On suppose que l'associativité est vérifiée pour tout triplet de mot u, v, w tel que le mot u est de taille n

Cas de base : $n = 0$

$\varepsilon.(v.w) = (\varepsilon.v).w$, ce qui fonctionne

Hérédité

On suppose que l'hypothèse de récurrence est vraie pour un n . Montrons-le pour $n + 1$

On suppose que u est de taille $n + 1$. On peut donc écrire

$$u = a.u'$$

avec u' de taille n

On a donc $(u.v).w = ((u'.a).v).w$

Par l'hypothèse de récurrence, on a $((u'.a).v).w = (u'.(a.v).w) = u'.((a.v).w)$

A finir

□

2 Les langages

Définition 1. Un langage sur un alphabet Σ est un ensemble de mots sur l'alphabet Σ

Exemple 2. Les mots sur $\{a, b\}$ qui débutent par ab :

$$aba, abab, abaaaab, \dots$$

En l'occurrence, cet ensemble de mots est infini, par exemple : $\{(ab)^i \mid i \geq 0\}$

Cas particulier du langage singleton : C'est un langage qui ne contient qu'un seul mot : $\{\text{poulet roti}\}$

Exemple 3. Un langage plus complexe

Le langage $www = \{\text{ensemble des mots qui représente une page web en HTML}\}$

Un problème de décision : Le mot est-il dans le langage ?

2.1 Opérations sur les langages

- i. L, K deux langages. L'union et l'intersection sur le même alphabet
- ii. L^c : Le complément : les mots qui sont sur le même alphabet mais pas sur L
- iii. La concaténation : Soient L, K deux langages. On note $L.K = \{u.v | u \in L, v \in K\}$

Exemple 4. *Opérations particulières*

$$\emptyset.K = \emptyset$$

$$\{\varepsilon\}.K = K$$

$$\begin{cases} L^0 = \{\varepsilon\} \\ L^{i+1} = L.L^i \end{cases}$$

- iv. L'étoile de Kleene : $L^* = \bigcup_{i \in \mathbb{N}} L^i$. On peut aussi écrire $\{ab\}^*$

v. $L^+ = L.L^*$

Exemple 5. *L'étoile de Kleene avec un alphabet*

Soit Σ un alphabet, Σ^* est l'ensemble de tous les mots de Σ . $(\Sigma, ., \varepsilon)$ est un monoïde, c'est même le monoïde libre sur Σ

Des langages intéressants

- i. $\emptyset$: le langage vide
- ii. $\{\varepsilon\}$: le langage qui contient le mot vide

3 Les expressions rationnelles

La base / les atomes

- i. Des lettres d'un alphabet
- ii. ε
- iii. $\emptyset$

Si e, f sont une expresion logique, alors on a

Les opérations, rangées par ordre de priorité

- i. e^* l'étoile de Kleene
- ii. $e.f$ la concaténation
- iii. $e|f$, l'union
- iv. Les parenthèses

Exemple 7. *Exemple d'expression rationnelle*

- i. $\text{poulet}(\text{roti}|\text{basquaise})$
- ii. $(\text{poulet} \text{ roti}) | (\text{poulet} \text{ basquaise})$

Pour e une expression rationnelle, on note son langage $\mathcal{L}(e)$

Pour a une lettre :

- i. $\mathcal{L}(a) = \{a\}$
- ii. $\mathcal{L}(\varepsilon) = \{\varepsilon\}$
- iii. $\mathcal{L}(\emptyset) = \emptyset$
- iv. $\mathcal{L}(e^*) = \mathcal{L}(e)^*$
- v. $\mathcal{L}(e.f) = \mathcal{L}(e) \cdot \mathcal{L}(f)$
- vi. $\mathcal{L}(e|f) = \mathcal{L}(e) | \mathcal{L}(f)$
- vii. $\mathcal{L}((e)) = \mathcal{L}(e)$

Deux expressions sont équivalentes si elles dénotent le même langage

$$e_1 \equiv e_2 \iff \mathcal{L}(e) \equiv \mathcal{L}(f)$$

Exemple 8. *Quelques propriétés*

- i. $e_1|e_2 \equiv e_2|e_1$ (*commutativité*)
- ii. $e_1|e_1 \equiv e_1$ (*idempotence*)
- iii. $e_1 \cdot (e_2|e_3) \equiv e_1 \cdot e_2 | e_1 \cdot e_3$

Définition 2 (Langage rationnel). *Un langage L est rationnel s'il existe une expression rationnelle e tel que $\mathcal{L}(e) = L$*

4 Les Automates

On a vu ce qu'était un langage rationnel. On va désormais voir comment grep et consors fonctionne

Définition 3 (Automate). *Un automate est un diagramme représentant un programme informatique.*

Un automate est une machine à état fini

Un automate est essentiellement :

- i. *Des états*
- ii. *Des transitions entre les états qui dépendent d'événements*

Chez nous, un automate va lire un mot une lettre à la fois, et mettre à jour son état à la fin de la lecture, il accepte ou rejette le mot

Voir le cours pour un exemple



Formellement, un automate est un tuple $(Q, \Sigma, \delta, i, F)$ où

- i. Q est un ensemble fini d'états
- ii. Σ un alphabet
- iii. $\delta : Q \times E \mapsto Q$ les transitions
- iv. i : l'etat initial tel que $i \in Q$
- v. $F \subset Q$: Les états finaux

4.1 Les exécutions d'automates

Pour $A = (Q, \Sigma, \delta, i, F)$ on définit $c_A : \Sigma^* \mapsto Q$ la fonction qui associe un mot à l'état qu'il atteint dans A

- $c_A(e) = i$
- On pose $u = u'.a$ et on suppose par induction que $c_A(u') = q$
- $c_A(u) = \delta(q, a)$

Définition 4. u est calculé par A si $c_A(u) \in F$

On note $\mathcal{L}(A)$ le langage des mots calculés par A

Un langage est reconnaissable s'il existe un automate A tel que $\mathcal{L}(A) = L$

Atome avec des automates

- $\emptyset$:

L'union des langages reconnaissables

$$L = \mathcal{L}(A), K = \mathcal{L}(B)$$

$\exists X$ un automate tel que $\mathcal{L}(C) = L \cup K$

On prend $A = (Q_A, \Sigma, \delta_A, i_A, F_A)$ $B = (Q_B, \Sigma, \delta_B, i_B, F_B)$

On a donc :

- $Q_C = Q_A \times Q_B$
- $i_c = (i_A, i_B)$
- $\delta_C((q, q'), a) = (\delta_A(q, a), \delta_B(q', a))$
- $F_C : \{(q, q') \in Q_C | q \in F_A \vee q' \in F_B\}$

Qui représente l'automate produit cartésien de A et B

Preuve. On va montrer que cette définition est correcte

$$c_C : \Sigma' \mapsto Q_C.$$

$c_C(u)$ c'est l'état d'arrivée dans C après avoir lu u

$$c_C = (c_A(u), c_B(u))$$

Cas de base :

$$c_C(\varepsilon) = (c_A, c_B) = (c_A(\varepsilon), c_B(\varepsilon))$$

Hérédité :

$$c_C(u.a) = \delta_C(q, a) \text{ avec } q_C = c_C(u) \text{ par HR}$$

$$q_C = (c_A(u), c_B(u)) = (q, q')$$

□

Le complémentaire de L est $L^c = \mathcal{L}(B)$ tel que $B = (Q, \Sigma, \delta, i, Q \setminus F)$

5 Les automates non déterministes

Rappel

Si E est un ensemble, $\mathcal{P}(E)$ est l'ensemble des sous ensembles de E

Définition 5. *A un automate non déterministe est un tuple*

$$(Q, \Sigma, \delta, I, F).$$

où

- Q est un ensemble fini d'états
- Σ est un alphabet
- $\delta : Q \times \Sigma \rightarrow \mathcal{P}(Q)$
- $I \subset Q$
- $F \subset Q$

Par exemple, on veut représenter ce langage

$$\Sigma^* aba \Sigma^*.$$

On fait ceci :

Cet automate est non déterministe : a permet de transitionner sur 0 ou 1

Formellement, on peut le décrire ainsi




Figure 1: Automate non déterministe

Exemple 9. Voir pdf sur le fil

5.1 Le calcul des automates non déterministes

$$A = (Q, \Sigma, \delta, I, F)$$

On définit $N_A : \Sigma^* \mapsto \mathcal{P}(Q)$ qui associe à l'ensemble des états qu'il atteint dans A


Par induction sur les mots de Σ^*

$$\begin{cases} N_A(\varepsilon) = I \\ N_A(u.a) = \bigcup_{q \in N_A u} \delta(q, a) \end{cases}$$

u est accepté par A si $N_A(u) \cap F \neq \emptyset$

Théorème 1. Soit $A = (Q, \Sigma, \delta, I, F)$ Un automate non déterministe. Il existe B un automate déterministe tel que $\mathcal{L}(A) = \mathcal{L}(B)$

Preuve. On va construire B explicitement



Formellement :

On définit

- $Q' = \{N_A(u) \mid u \in \Sigma^*\}$
- Σ
- $\delta' : Q' \times \Sigma \mapsto Q'$ pour $E \in Q', \delta'(E, a) = \bigcup_{q \in E} \delta(q, a) \in Q'$
- $i = I \in Q'$

- $F = (E \in Q' | E \cap F \neq \emptyset)$

□

5.2 Opération sur les unions

Cloture par union (facile)


Cloture par L^+

Soit A un automate déterministe sur L et on veut calculer B pour L^+

Exemple 10. *Exemple d'une telle construction*

Le langage : $\{a, b\}$

En rajoutant la transition de 1 à 0, on obtient $(ab)^*$



$$A = (Q, \Sigma, \delta, i, F) \quad B = (Q, \Sigma, \delta', \{i\}, F)$$

$$\forall q, a \quad \delta(q, a) = \begin{cases} \{\delta(q, a)\} & \text{si } \delta(q, a) \notin F \\ \{i, \delta(q, a)\} & \text{sinon} \end{cases}$$

Cloture par concaténation

$$A = (Q_A, \Sigma, \delta_A, i_A, F_A)$$

$$B = (Q_B, \Sigma, \delta_B, i_B, F_B)$$

On veut C tel que $\mathcal{L}(C) = \mathcal{L}(A) \cdot \mathcal{L}(B)$

$$Q_C = Q_A \cup Q_B \text{ (disjoints)}$$

$$\bullet \delta_C : (q, a) \mapsto \begin{cases} \text{Si } q \in Q_A \text{ alors} \\ \{\delta_A(q, a)\} & \text{si } \delta_A(q, a) \notin F_A \\ \{\delta_A(q, a), i_B\} & \text{sinon} \\ \text{Si } q \in Q_B, (\delta_B(q, b)) \end{cases}$$

$$\bullet I_C = \{i_A\}$$


$$\bullet F_C = F_B$$

6 Expressivité des langages rationnels


Théorème 2 (De Kleene). *Un langage est rationnel si et seulement si il est reconnaissable*

Pour un langage reconnaissable, comment obtenir une expression rationnelle ?


On va réaliser une élimination des états




L'automate reconnaissant le langage Σ^*b



Elimination de 1



Elimination de 0




7 Automate généralisé

Un automate généralisé est un tuple de la forme

- Q : Un ensemble fini
- Σ : un alphabet
- $\delta : Q^2 \mapsto \text{Rationnel}(\Sigma)$
- debut $\in Q$
- fin $\in Q$

Exemple 11 (Exemple d'automate généralisé).



Un mot u est accepté par un automate généralisé $A = (Q, \Sigma, \delta, \text{début}, \text{fin})$ s'il existe une suite $q_1, \dots, q_p \in Q$ tel que $u \in \mathcal{L}(\delta(\text{début}, q_1), \delta(q_1, q_2), \dots, \delta(q_p, \text{fin}))$

Avec $\mathcal{L}(A)$ les mots acceptés par A

On prend $A = (Q, \Sigma, \delta, i, F)$ un automate déterministe et $B = (Q', \Sigma, \delta, \text{debut}, \text{fin})$

On a donc ces relations entre A et B


- $Q' = Q \cup \{\text{debut}, \text{fin}\}$
- $\delta' : (q, q') \begin{cases} \emptyset & \text{si } \forall a \in \Sigma \delta(q, a) = q' \\ a_1 | a_2 | \dots | a_p & \text{si } \delta(q, q_i) \forall i \in \dots \text{ pour } q, q' \neq \text{debut}, \text{fin} \end{cases}$
- $\delta'(\text{debut}, q) = \begin{cases} \varepsilon & \text{si } q = i \\ \emptyset & \text{sinon} \end{cases}$
- $\delta'(q, \text{fin}) = \begin{cases} \varepsilon & \text{si } q \in F \\ \emptyset & \text{sinon} \end{cases}$

Pour $A = (Q, \Sigma, \delta, \text{début}, \text{fin})$ un automate généralisé $Q \in Q \setminus \{\text{début}, \text{fin}\}$


On construit $B = \{Q \setminus \{q\}, \Sigma, \delta', \text{debut}, \text{fin}\}$ tel que $\mathcal{L}(A) = \mathcal{L}(B)$

On va chercher :

- Dans A :



- Dans B :



Avec $e' = \delta(q_0, q_1)$

On pose alors :

$$\delta'(q_0, q_1) = \delta(q_0, q_1) \mid \delta(q_0, q) \delta(q, q)^* \delta(q, q_1) \forall (q_0, q_1) \in Q'.$$

Pour tout automate déterministe, il existe une expression rationnelle qui dénote son langage


Preuve. i. On prend A déterministe on calcule B généralisé tel que $\mathcal{L}(A) = \mathcal{L}(B)$

ii. On élimine les états B et on obtient C qui a une unique transition entre le début et la fin

Comme $\mathcal{L}(A) = \mathcal{L}(B) = \mathcal{L}(C)$ □

Soit e une expression rationnelle. Alors il existe un automate déterministe A tel que $\mathcal{L}(e) = \mathcal{L}(A)$

Par induction sur l'expression :



Cas inductif :

e et f avec A et B tel que $\mathcal{L}(e) = A, \mathcal{L}(f) = B$

$$\mathcal{L}(e.f) = \mathcal{L}(e) . \mathcal{L}(f)$$

calculable par un automate non déterministe, qu'on peut déterminer :)

De même pour :

- $e|f$
- e^*

Ce qui conclut le théorème de Kleene

8 Lemme de l'étoile

L un langage calculé par un automate A avec n états. Si $u \in L$ avec $\|u\| > n$, alors il existe p, v et s tel que :


- $u = pvs$
- $pv^*s \in L$

Preuve. $u \in L$ avec $\|u\| > n$ alors il existe $i < j < \|u\|$ tel que :

$$C_A(u[:i]) = C_A(u[:j]).$$

par le lemme des tiroirs

Donc on a la situation suivante :



□

Cas d'application

$$L = (a^n b^n | n \in \mathbb{N}).$$

n'est pas reconnaissable

Par l'absurde :

S'il existe un automate de taille p qui le calcule

$a^p b^p$, il existe p, v, s tel que $a^p b^p = pvs$ et $pv^*s \subset L$ (application du Lemme de l'étoile)

Si le v est un sous mot de a^p , on a $pv^p s = a^{p'} b^p$ avec $p' > p \notin L$

Si v est un sous mot de b^p , on a donc $pv^p s = a^p b^{p'}$ avec $p' > p$


Si v est à cheval, on a $pv^p s = a^* b^*$ et donc pas dans L

Donc, un automate ne peut pas exister


9 Minimisation d'automate déterministe

Prenons l'exemple de l'expression rationnelle : $\Sigma^* (ab|ba|aa) \Sigma^* |a$


Construisons naïvement l'automate associé



En le déterminisant, on obtient :



Elle peut se simplifier en :



Mais il faut un peu réfléchir pour arriver à ça... Il faut trouver une méthode pour simplifier un automate plus facilement

9.1 Le test du vide

Si on prend deux automates, comment savoir s'ils calculent le même langage

- Tester si un langage reconnaissable est vide $\text{Accessible}(A, n) \subset Q$ les états qu'on peut atteindre avec un mot de taille n :

– cas de base : $\text{Accessible}(A, c) = I$

– $\text{Accessible}(A, n+1) = \bigcup_{q \in \text{Accessible}(A, n), a \in \Sigma} \delta(q', a)$

$$\text{Accessible}(A) = \bigcup_{n \in \mathbb{N}} \text{Accessible}(A, n) = \bigcup_{n \leq \|A\|} \text{Accessible}(A, n)$$

- Un mot est accepté si : $F \cap \text{Accessible}(A) \neq \emptyset$
- L, K reconnaissable. On peut vérifier algorithmiquement que $L = K$ en vérifiant que ;

$$\begin{cases} (L \cap K^c) = \emptyset \\ (L^c \cap K) = \emptyset \end{cases}$$

Définition 6 (Résiduel). • $L \subset \Sigma^*$ un langage

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

Exemple 12. $L = (ab)^*$

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

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

$$b^{-1}L = \emptyset$$

Si on prend un automate $A = (Q, \Sigma, \delta, i, F)$ déterministe et $A_q = (Q, \Sigma, \delta, q, F)$ avec $q \in \text{Accessible}(A)$

On a que $\mathcal{L}(A_q) = u^{-1}L$ pour un mot tel que $c_A(u) = q$

$\forall u, v \in \Sigma^*$ tel que $c_A(u) = c_A(v)$, alors $u^{-1}L = v^{-1}L$

Grâce à ça, un automate qui calcule un langage L a au moins autant d'états que de résidus de L

9.2 L'automate des résidus

On fixe L un langage reconnaissable et on pose $R = \{u^{-1}L \mid u \in \Sigma^*\}$

On a que $\|R\|$ est plus petit que la taille d'un automate déterministe qui calcule L

$$A_r = (R, \Sigma, \delta_r, L, F_r)$$

$$\delta_r : \begin{cases} R \times \Sigma \mapsto R \\ (u^{-1}L, a) \mapsto (ua)^{-1}L = a^{-1}(u^{-1}L) \text{ (admis)} \end{cases}$$

$$F_r = \{K \in R \mid \varepsilon \in K\}$$

Par construction, l'automate des résidus reconnaît L . C'est donc un automate minimal.


Tous les automates de cette taille sont en fait "égaux" (à isomorphisme près), c'est l'automate canonique

Comment construire l'automate minimal ?

Il faut identifier les états qui calculent le même résidu et les regrouper

Exemple 13. *Minimisation d'un automate*

Prenons l'automate suivant :




On a $L = (ab)^*$

- $0 \mapsto L$
- $1 \mapsto a^{-1}L = b(ab)^*$

- $2 \mapsto b^{-1}L = \emptyset$
- $3 \mapsto (ab)^*L = \emptyset$

Exemple 14. *Un autre exemple*

b



- $0 \mapsto \varepsilon^{-1}L = L$
- $a^{-1}L = \Sigma^*$
- $b^{-1}L = L$
- $(aa)^{-1}L = \Sigma^*$