

Langages formels : hauteur(s) d'étoile

Stéphane Le Roux leroux@lsv.fr

ENS Paris-Saclay

2023-2024

Expressions rationnelles (rappel)

Syntaxe : Soit Σ un alphabet fini et non-vidé. Les expressions rationnelles sur Σ sont des mots sur l'alphabet $\underline{\Sigma} \cup \{ (,), +, \cdot, *, \emptyset \}$. Leur ensemble $\text{ER}(\Sigma)$ est défini par récurrence structurée.

- $\emptyset \in \text{ER}(\Sigma)$
- Pour tout $a \in \Sigma$, on pose $\underline{a} \in \text{ER}(\Sigma)$
- Pour tout $E, F \in \text{ER}(\Sigma)$ on pose
 - ▶ $(E + F) \in \text{ER}(\Sigma)$
 - ▶ $(E \cdot F) \in \text{ER}(\Sigma)$
 - ▶ $(E^*) \in \text{ER}(\Sigma)$

Sémantique : À chaque expression rationnelle sur Σ , on associe un langage sur Σ , par récurrence structurée.

- $\mathcal{L}(\emptyset) := \emptyset$
- Pour tout $a \in \Sigma$, on pose $\mathcal{L}(\underline{a}) := \{a\}$
- Pour tout $E, F \in \text{ER}(\Sigma)$ on pose
 - ▶ $\mathcal{L}(E + F) := \mathcal{L}(E) \cup \mathcal{L}(F)$
 - ▶ $\mathcal{L}(E \cdot F) := \mathcal{L}(E) \cdot \mathcal{L}(F)$
 - ▶ $\mathcal{L}(E^*) := \mathcal{L}(E)^*$

Expressions rationnelles avec mot vide explicite

Expressions rationnelles, déf. alternative avec mot vide explicite, ER_ϵ

- Ajout d'un cas à la définition de la syntaxe par récurrence structurelle.
 $ER_\epsilon ::= \underline{\emptyset} \mid \underline{\Sigma} \mid ER_\epsilon + ER_\epsilon \mid ER_\epsilon \cdot ER_\epsilon \mid ER_\epsilon^* \mid \underline{\epsilon}$
- Ajout d'un cas à la définition de la sémantique par récurrence structurelle : $\mathcal{L}(\underline{\epsilon}) := \{\epsilon\}$.

Lemme

Un langage est définissable par expressions rationnelles ssi il l'est par expressions rationnelles avec mot vide explicite.

- $ER(\Sigma) \subseteq ER_\epsilon(\Sigma)$ et $\mathcal{L}[ER(\Sigma)] \subseteq \mathcal{L}[ER_\epsilon(\Sigma)]$
- Soit $f : ER_\epsilon(\Sigma) \rightarrow ER(\Sigma)$ définie par réc. struct. sur l'argument.
 - ▶ $f(\underline{\emptyset}) := \underline{\emptyset}$ et $f(\underline{a}) := \underline{a}$.
 - ▶ $f(E + F) := f(E) + f(F)$ et $f(E \cdot F) = f(E) \cdot f(F)$ et $f(E^*) = f(E)^*$
 - ▶ $f(\underline{\epsilon}) := \underline{\emptyset}^*$

On peut montrer par réc. struct. que f est bien à valeur dans $ER(\Sigma)$ et que $\forall E \in ER_\epsilon(\Sigma), \mathcal{L}(E) = \mathcal{L}(f(E))$. Donc $\mathcal{L}[ER_\epsilon(\Sigma)] \subseteq \mathcal{L}[ER(\Sigma)]$

Hauteur d'étoile

Hauteur d'étoile d'une expression rationnelle avec mot vide explicite

- $h(\emptyset) := h(\epsilon) := h(a) := 0$ pour tout $a \in \Sigma$.
- $h(E + F) := h(E \cdot F) := \max(h(E), h(F))$
- $h(E^*) := 1 + h(E)$

Exemples

- $\underline{a} + \underline{\epsilon}$
- $(\underline{a} \cdot (\underline{b} + \underline{\epsilon})) + (\underline{b} \cdot \underline{b} \cdot \underline{a})$
- $\underline{a}^* \cdot (\underline{b}^* + (\underline{a} \cdot \underline{b})^*)$
- $(\underline{a}^* \cdot \underline{b})^*$
- $(\underline{a}^*)^*$

Hauteur d'étoile d'un langage

La hauteur d'étoile d'un langage rationnel est la hauteur d'étoile minimale d'une expression rationnelle avec mot vide le définissant.

Hauteur d'étoile nulle

$ER_{0,\epsilon}(\Sigma)$

- Retrait du cas de l'étoile à la définition de $ER_{\epsilon}(\Sigma)$:
 $\mathcal{E} ::= \underline{\emptyset} \mid \underline{\Sigma} \mid \mathcal{E} + \mathcal{E} \mid \mathcal{E} \cdot \mathcal{E} \mid \underline{\epsilon}$
où \mathcal{E} est un raccourci pour $ER_{0,\epsilon}(\Sigma)$.
- Retrait du cas de l'étoile à la définition de la sémantique par récurrence structurelle.

Lemme

Soit $E \in ER_{\epsilon}$. Alors $E \in ER_{0,\epsilon}$ ssi $h(E) = 0$.

- Mq $\forall E \in ER_{0,\epsilon}, h(E) = 0$ par récurrence sur E .
 - ▶ $h(\underline{\emptyset}) := h(\underline{\epsilon}) := h(\underline{a}) := 0$ pour tout $a \in \Sigma$.
 - ▶ $h(E + F) := h(E \cdot F) := \max(h(E), h(F)) = 0$ par HR.
- Mq $\forall E \in ER_{\epsilon}, h(E) = 0 \Rightarrow E \in ER_{0,\epsilon}$
 - ▶ $\underline{\emptyset}, \underline{a} \in ER_{0,\epsilon}$, donc l'implication est vraie quelque soit sa prémisse.
 - ▶ Si $h(E + F) = 0$, alors $h(E) = h(F) = 0$, d'où $E, F \in ER_{0,\epsilon}$ par HR, et $E + F \in ER_{0,\epsilon}$ par définition de $ER_{0,\epsilon}$. Pareil pour $E \cdot F$.
 - ▶ $h(E^*) \neq 0$, donc $h(E^*) = 0 \Rightarrow E^* \in ER_{0,\epsilon}$.

Hauteur d'étoile nulle (II)

Théorème

Soit Σ un ensemble fini et $L \in \Sigma^*$. Les trois assertions suivantes sont équivalentes.

- 1 L est fini.
- 2 $L \in \mathcal{L}[\text{ER}_{0,\epsilon}(\Sigma)]$
- 3 L est de hauteur d'étoile nulle.

Montrons 1 \Leftrightarrow 2.

- 1 \Rightarrow 2. Posons $E_\epsilon := \underline{e}$ et $\forall ua \in \Sigma^+, E_{ua} := (E_u \cdot \underline{a})$. On a $\forall u \in \Sigma^+, \mathcal{L}(E_u) = \{u\}$, prouvable par récurrence sur u . Soit $L = \{u^1, \dots, u^n\} \subseteq \Sigma^*$ fini. Si $L = \emptyset$ alors $L = \mathcal{L}(\emptyset)$ avec $\emptyset \in \text{ER}_{0,\epsilon}(\Sigma)$. Sinon, soit $E = (\dots (E_{u^1} + E_{u^2}) \dots) + E_{u^{n-1}} + E_{u^n}$. Alors $E \in \text{ER}_{0,\epsilon}(\Sigma)$ et $L = \mathcal{L}(E)$.
- 2 \Rightarrow 1. Mq $\forall E \in \text{ER}_{0,\epsilon}(\Sigma), |\mathcal{L}(E)| \in \mathbb{N}$, par réc. struct. sur E .
 - ▶ $|\mathcal{L}(\emptyset)| = 0$ et $|\mathcal{L}(\underline{\epsilon})| = |\mathcal{L}(\underline{a})| = 1$.
 - ▶ $|\mathcal{L}(E + F)| \leq |\mathcal{L}(E)| + |\mathcal{L}(F)|$ et $|\mathcal{L}(E \cdot F)| \leq |\mathcal{L}(E)||\mathcal{L}(F)|$ sont finis si $|\mathcal{L}(E)|$ et $|\mathcal{L}(F)|$ le sont.

Hauteur d'étoile arbitraire

Théorème

Pour tout $n \in \mathbb{N}$ il existe un langage rationnel de hauteur d'étoile n .

Preuve

En TD ?

Expressions rationnelles avec mot vide et complément

Expressions rationnelles avec mot vide et complément, $ER_{\epsilon, c}$

Ci-dessous, on écrit \mathcal{E} ou lieu de $ER_{\epsilon, c}$.

- $\mathcal{E} ::= \underline{\emptyset} \mid \underline{\Sigma} \mid \mathcal{E} + \mathcal{E} \mid \mathcal{E} \cdot \mathcal{E} \mid \mathcal{E}^* \mid \underline{\epsilon} \mid \mathcal{E}^c$
- $\mathcal{L}(E^c) := \Sigma^* \setminus \mathcal{L}(E)$.

Lemme

$$\mathcal{L}[ER] = \mathcal{L}[ER_{\epsilon, c}]$$

Preuve

- $ER \subseteq ER_{\epsilon, c}$ et $\mathcal{L}[ER] \subseteq \mathcal{L}[ER_{\epsilon, c}]$
- Pas de moyen simple de traduire $E \in ER_{\epsilon, c}$ en $f(E) \in ER$. Pour tout $E \in ER_{\epsilon, c}$, construisons un (ϵ) -AFN \mathcal{A}_E telle que $\mathcal{L}(\mathcal{A}_E) = \mathcal{L}(E)$.
Par récurrence sur E .
 - ▶ Pour les cas autres que E^c , on invoque les constructions vues en cours.
 - ▶ Pour E^c , on détermine \mathcal{A}_E avant d'inverser les états acceptants.

Langages sans étoile

Expressions sans étoile et avec complément

$ER_{0,c}$ est défini par $\mathcal{E} ::= \underline{\emptyset} \mid \underline{\Sigma} \mid \mathcal{E} + \mathcal{E} \mid \mathcal{E} \cdot \mathcal{E} \mid \mathcal{E}^c$

Langage sans étoile

Un langage est dit sans étoile s'il est définissable par une expression de $ER_{0,c}$

- $\Sigma^* = \mathcal{L}(\underline{\emptyset}^c)$
- $\Sigma^* a \Sigma^* b b \Sigma^* = \mathcal{L}(\underline{\emptyset}^c \cdot \underline{a} \cdot \underline{\emptyset}^c \cdot \underline{b} \cdot \underline{b} \cdot \underline{\emptyset}^c)$
- $\{\epsilon\} = \Sigma^* \setminus \cup_{a \in \Sigma} a \Sigma^* = \mathcal{L}((\cup_{a \in \Sigma} \underline{a} \cdot \underline{\emptyset}^c)^c)$
- $(ab)^+ = (a \Sigma^* \cap \Sigma^* b) \setminus \Sigma^* (aa + bb) \Sigma^*$ (pour $a \neq b$)
- $(ab)^* = (ab)^+ + \epsilon$
- $(aa)^*$ n'est pas sans étoile. Et $(aa)^+$?

Autres expressions rationnelles

- Rappel : $ER_{\epsilon,c}$ est défini par $\mathcal{E} ::= \underline{\emptyset} \mid \underline{\Sigma} \mid \mathcal{E} + \mathcal{E} \mid \mathcal{E} \cdot \mathcal{E} \mid \mathcal{E}^* \mid \underline{\epsilon} \mid \mathcal{E}^c$.
- Rappel : $ER_{0,c}$ est défini par $\mathcal{E} ::= \underline{\emptyset} \mid \underline{\Sigma} \mid \mathcal{E} + \mathcal{E} \mid \mathcal{E} \cdot \mathcal{E} \mid \mathcal{E}^c$

Expressions sans étoile, avec mot vide et complément

$ER_{0,\epsilon,c}$ est défini par $\mathcal{E} ::= \underline{\emptyset} \mid \underline{\Sigma} \mid \mathcal{E} + \mathcal{E} \mid \mathcal{E} \cdot \mathcal{E} \mid \underline{\epsilon} \mid \mathcal{E}^c$

Lemme

$$\mathcal{L}[ER_{0,\epsilon,c}] = \mathcal{L}[ER_{0,c}]$$

Preuve par double inclusion.

- On a $ER_{0,c} \subseteq ER_{0,\epsilon,c}$ et $\mathcal{L}[ER_{0,c}] \subseteq \mathcal{L}[ER_{0,\epsilon,c}]$.
- On a $\forall E \in ER_{0,\epsilon,c} \exists f(E) \in ER_{0,c}, \mathcal{L}(f(E)) = \mathcal{L}(E)$. En effet, on remplace $\underline{\epsilon}$ par $(+_{a \in \Sigma} \underline{\emptyset}^c \cdot \underline{a} \cdot \underline{\emptyset}^c)^c$ par réc. sur $E \in ER_{0,\epsilon,c}$. D'où $\mathcal{L}[ER_{0,\epsilon,c}] \subseteq \mathcal{L}[ER_{0,c}]$.

Hauteur d'étoile généralisée

Hauteur d'étoile dans $ER_{\epsilon, c}$

- $H(\emptyset) := H(\underline{\epsilon}) := H(\underline{a}) := 0$ pour tout $a \in \Sigma$.
- $H(E + F) := H(E \cdot F) := \max(H(E), H(F))$
- $H(E^*) := 1 + H(E)$
- $H(E^c) := H(E)$

- $(\underline{a} \cdot (\underline{b} + \underline{\epsilon})^c) + (\underline{b} \cdot \underline{b} \cdot \underline{a})$
- $((\underline{a}^* \cdot \underline{b})^c)^* + (((\underline{a}^c)^c)^c)^c$

Hauteur d'étoile généralisée d'un langage

La hauteur d'étoile généralisée d'un langage rat. est la hauteur d'étoile minimale d'une expression rat. avec ϵ et complément le définissant.

- Lemme : $H(L) \leq h(L)$
- On ne sait pas (encore) s'il existe des langages rationnels de hauteur d'étoile généralisée 2 ou plus.

Langages sans étoile (II)

- Rappel dans $ER_{\epsilon,c}$:
 - ▶ $H(\emptyset) := H(\underline{\epsilon}) := H(\underline{a}) := 0$ pour tout $a \in \Sigma$.
 - ▶ $H(E + F) := H(E \cdot F) := \max(H(E), H(F))$
 - ▶ $H(E^*) := 1 + H(E)$
 - ▶ $H(E^c) := H(E)$
- Rappel : $ER_{0,c}$ est défini par $\mathcal{E} ::= \underline{\emptyset} \mid \underline{\Sigma} \mid \mathcal{E} + \mathcal{E} \mid \mathcal{E} \cdot \mathcal{E} \mid \mathcal{E}^c$

Lemme

Un langage rationnel est sans étoile ssi il est de hauteur d'étoile généralisée nulle.

Preuve

$L \subseteq \Sigma^*$ est sans étoile ssi $\exists E \in ER_{0,c}$ telle que $L = \mathcal{L}(E)$, ssi $\exists E \in ER_{0,\epsilon,c}$ telle que $L = \mathcal{L}(E)$ (car $\mathcal{L}[ER_{0,c}] = \mathcal{L}[ER_{0,\epsilon,c}]$)

- $ER_{0,c} \subseteq ER_{\epsilon,c}$. On a $\forall E \in ER_{0,c}$, $H(E) = 0$, par récurrence facile sur E .
- On a $\forall E \in ER_{\epsilon,c}$, $H(E) = 0 \Rightarrow E \in ER_{0,\epsilon,c}$, par réc. facile sur E .

Avant-goût du théorème de Schützenberger

Théorème de Schützenberger, 1965

Soit L un langage rationnel. Les trois assertions suivantes sont équivalentes.

- 1 L est sans étoile
- 2 Le monoïde syntaxique de L est fini et apériodique
- 3 L est reconnu par un monoïde fini et apériodique

Retour sur les monoïdes

Monoïde apériodique

Un groupe (G, \cdot_G, e_G) est dit contenu dans un monoïde (M, \cdot_M, e_M) si

- $G \subseteq M$
- $\forall x, y \in G, x \cdot_G y = x \cdot_M y$

Si de plus $e_G = e_M$, on parle de sous-groupe d'un monoïde.

Un monoïde est dit apériodique s'il ne contient que des groupes triviaux, i.e. réduits à un élément.

"Poêle à frire"

Soit M un monoïde fini. Pour tout $x \in M$, soient $l_x \geq 0$ et $p_x > 0$ tels que $x^{l_x+p_x} = x^{l_x}$ et $l_x + p_x$ minimal pour cette propriété.

- Donc $1, x, \dots, x^{l_x+p_x-1}$ sont distincts deux à deux.
- Si $l \geq 0$ et $p > 0$ tel que $x^l = x^{l+p}$, alors $l_x \leq l$ et $p_x \leq p$.

Caractérisation des groupes et monoïdes aperiodiques

Proposition

Soit M un monoïde fini. Les assertions suivantes sont équivalentes.

- 1 M est un groupe.
- 2 Pour tout $x \in M$, on a $l_x = 0$ (donc $x^{p_x} = 1$).
- 3 $\exists k > 0, \forall x \in M, x^k = 1$

Lemme

$G_x := \{x^{l_x}, \dots, x^{l_x+p_x-1}\}$ est un groupe.

Lemme

Soit M un monoïde fini. Les assertions suivantes sont équivalentes.

- 1 M est un monoïde aperiodique.
- 2 Pour tout $x \in M$, on a $p_x = 1$ (et donc $x^{l_x+1} = x^{l_x}$)
- 3 $\exists k \in \mathbb{N}, \forall x \in M, x^{k+1} = x^k$

Théorème de Schützenberger

Exemple

Soit $\Sigma := \{a\}$ et $L := (aa)^+$. Alors $(\Sigma^* / \approx_L) = \{[\epsilon], [aa], [a]\}$. De plus $\{[aa], [a]\}$ est un groupe, donc Σ^* / \approx_L n'est pas a périodique.

Théorème de Schützenberger, 1965

Soit L un langage rationnel. Les trois assertions suivantes sont équivalentes.

- 1 L est sans étoile
- 2 Le monoïde syntaxique de L est fini et a périodique
- 3 L est reconnu par un monoïde fini et a périodique

Preuve de 2 \Rightarrow 3

Le monoïde syntaxique reconnaît L (via la surjection canonique)

Preuve du théorème de Schützenberger, $3 \Rightarrow 2$

Rappel : Si un monoïde M reconnaît $L \subseteq \Sigma^*$, alors Σ^* / \approx_L est isomorphe à un quotient d'un sous-monoïde de M

Lemme

- 1 Tout sous-monoïde d'un monoïde aperiodique est aperiodique.
- 2 Tout quotient d'un monoïde aperiodique est aperiodique.

Preuve

- 1 Les groupes inclus dans le sous-monoïde sont aussi inclus dans le monoïde de départ.
- 2 Soit k tel que $\forall x \in M, x^{k+1} = x^k$. Soit \sim une congruence sur M . Alors $[x]_{\sim}^{k+1} = [x^{k+1}]_{\sim} = [x^k]_{\sim} = [x]_{\sim}^k$.

Corollaire, $3 \Rightarrow 2$

Si M reconnaissant L est aperiodique, alors Σ^* / \approx_L l'est aussi

Preuve du théorème de Schützenberger, $1 \Rightarrow 2$

Lemme

Le monoïde syntaxique d'un langage rationnel L est apériodique ssi il existe $k \in \mathbb{N}$ tel que $\forall x, y, z \in \Sigma^*$, $xy^kz \in L \Leftrightarrow xy^{k+1}z \in L$

Pour tout langage L de monoïde syntaxique apériodique soit $i(L)$ le plus petit entier k vérifiant la formule du lemme ci-dessus.

Lemme

- Le langage vide et les $\{a\}$ ont des monoïdes syntaxiques apériodiques.
- Les langages rationnels de monoïdes syntaxiques apériodiques sont clos par union, concaténation, complémentaire.
- plus précisément :
 - ▶ $i(\emptyset) = 0$ et $i(\{a\}) = 2$.
 - ▶ $i(\Sigma^* \setminus L) = i(L)$
 - ▶ $i(K \cup L) \leq \max(i(K), i(L))$.
 - ▶ $i(KL) \leq i(K) + i(L)$

$1 \Rightarrow 2$: Si L est un langage rationnel sans étoile, son monoïde syntaxique est apériodique.

Preuve du théorème de Schützenberger, $2 \Rightarrow 1$

Mq si le monoïde syntaxique de L est fini et apériodique, alors L est sans étoile

Pas dans ce cours.