

LF – Théorie des langages formels

Sylvain Brandel

2023 – 2024

sylvain.brandel@univ-lyon1.fr



CM 9

AUTOMATES À PILE

ALGÈBRICITÉ

Automates à pile

- Un **automate à pile** est un sextuplet $M = (K, \Sigma, \Gamma, \delta, s, F)$ avec :
 - K : ensemble fini d'états
 - Σ : ensemble fini de symboles d'entrée (alphabet)
 - Γ : ensemble fini de symboles de la pile
 - $s \in K$: état initial
 - $F \subset K$: ensemble des états finaux (**acceptants**)
 - $\Delta \subset (K \times (\Sigma \cup \{\varepsilon\}) \times (\Gamma \cup \{\varepsilon\})) \times (K \times (\Gamma \cup \{\varepsilon\}))$: relation de transition

Automates à pile

- Une **transition** $((q, \sigma, \gamma), (q', \gamma')) \in \Delta$ où :
 - q est l'état courant
 - σ est le symbole d'entrée courant
 - γ est le symbole sommet de la pile
 - q' est le nouvel état
 - γ' est le nouveau symbole en sommet de pile

a pour effet :

- (1) De passer de l'état q à l'état q'
- (2) D'avancer la tête de lecture après σ
- (3) De dépiler γ du sommet de la pile
- (4) D'empiler γ' sur la pile

Automates à pile

- Soit $M = (K, \Sigma, \Gamma, \delta, s, F)$ un automate à pile. Une **configuration** de M est définie par un triplet $(q, w, z) \in K \times \Sigma^* \times \Gamma^*$ où :
 - q est l'état courant de M
 - w est la partie de la chaîne restant à analyser
 - z est le contenu de la pile
 - Soient (q, w, z) et (q', w', z') deux configurations d'un automate à pile M . On dit qu'on passe de (q, w, z) à (q', w', z') **en une étape**
 - ssi $\exists \sigma \in \Gamma \cup \{\varepsilon\}$ et $\gamma, \gamma' \in \Gamma \cup \{\varepsilon\}$
 - tels que $w = \sigma w'$
 - et $z = \gamma z'', z' = \gamma' z''$ avec $z'' \in \Gamma^*$
 - et $((q, \sigma, \gamma), (q', \gamma')) \in \Delta$
- On note $(q, w, z) \vdash_M (q', w', z')$

Automates à pile

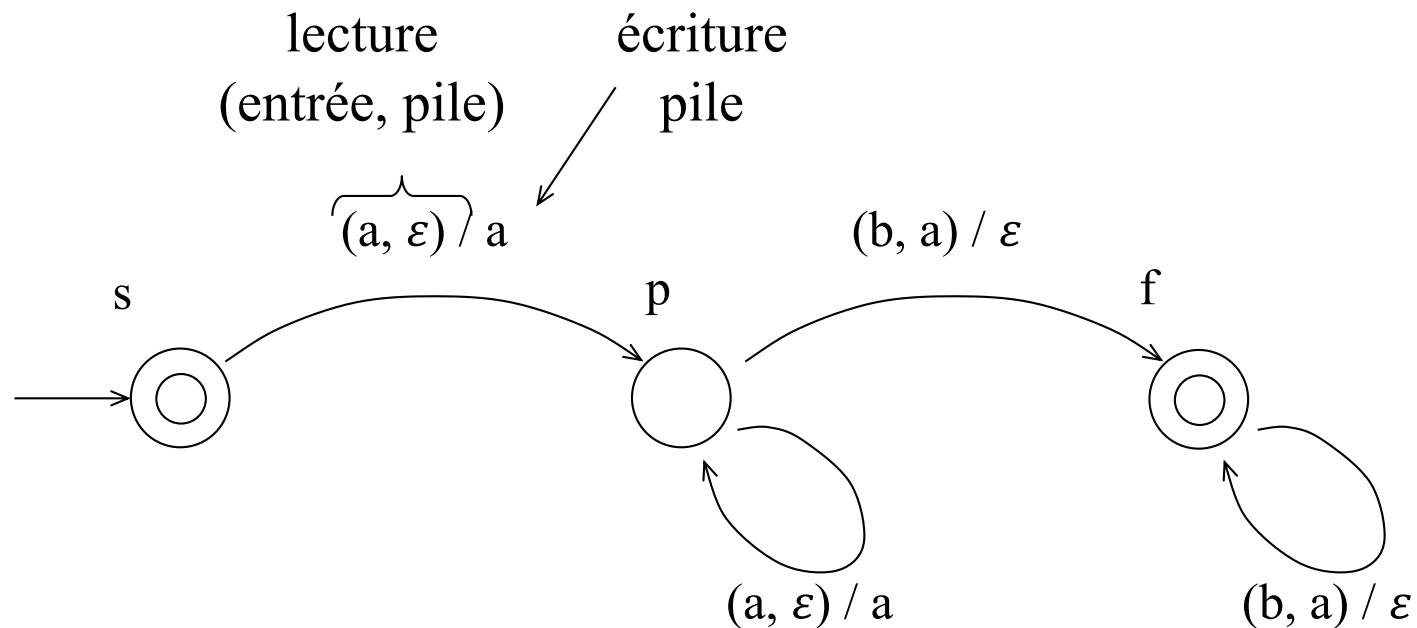
- La relation \vdash_M^* est la fermeture réflexive transitive de \vdash_M
- Soit $M = (K, \Sigma, \Gamma, \delta, s, F)$ un automate à pile

Un mot $w \in \Sigma^*$ est **accepté** par M ssi $(s, w, \varepsilon) \vdash_M^* (f, \varepsilon, \varepsilon)$ avec $f \in F$

- Le **langage accepté** par M , noté $L(M)$, est l'ensemble des mots acceptés par M

Automates à pile

- Exemple : Soit $M = (K, \Sigma, \Gamma, \delta, s, F)$ avec :
 - $K = \{s, p, f\}$ $\Delta = \{ ((s, a, \varepsilon), (p, a)),$
 - $\Sigma = \{a, b\}$ $((p, a, \varepsilon), (p, a)),$
 - $\Gamma = \{a, b\}$ $((p, b, a), (f, \varepsilon)),$
 - $F = \{s, f\}$ $((f, b, a), (f, \varepsilon)) \}$



Automates à pile

- Un automate à pile est **déterministe** s'il y a **au plus** une transition applicable pour tout triplet de la forme
(État courant, symbole d'entrée, sommet de pile).
- Les automates à pile non déterministes reconnaissent plus de langages que les automates à pile déterministes

Automates à pile et grammaires algébriques

- Théorème

La classe des langages acceptés par les automates à pile est égale à la classe des langages engendrés par les grammaires algébriques

- Un automate à pile est dit **simple** ssi quelle que soit la transition

$((q, \sigma, \gamma), (q', \gamma')) \in \Delta$, on a :

$\gamma \in \Gamma$ (sauf pour $q = s$ où on ne dépile rien)
et $|\gamma'| \leq 2$

- Proposition

On peut transformer tout automate à pile en un automate simple équivalent

Propriétés des langages algébriques

Preuve d'algébricité

- Pour montrer qu'un langage est **algébrique**, on peut :
 - Soit définir une grammaire algébrique qui engendre ce langage
 - Soit définir un automate à pile qui l'accepte
- Il est également possible d'utiliser les propriétés de stabilité de la classe des langages algébriques

Propriétés des langages algébriques

Propriétés de stabilité

- Théorème

*La classe des langages algébriques est **stable** par les opérations **d'union**, de **concaténation** et **d'étoile de Kleene***

- Preuve

Soient deux grammaires $G_1 = (V_1, \Sigma_1, R_1, S_1)$ et $G_2 = (V_2, \Sigma_2, R_2, S_2)$, avec $V_1 \cap V_2 = \emptyset$ (on renomme éventuellement les non-terminaux)

La preuve (constructive) consiste à :

- Construire une grammaire G à partir de G_1 et G_2 validant les propriétés de stabilité
- Montrer que $L(G) = L(G_1) \text{ op } L(G_2)$ ($\text{op} \in \{\cup, \cdot\}$) et $L(G) = L(G_1)^*$

Propriétés des langages algébriques

Propriétés de stabilité

- Preuve

(a) **Union**

Soit $G = (V, \Sigma, R, S)$ avec :

- $V = V_1 \cup V_2 \cup \{S\}$ où $S \notin V_1 \cup V_2$ (renommage éventuel)
- $\Sigma = \Sigma_1 \cup \Sigma_2$
- $R = R_1 \cup R_2 \cup \{S \rightarrow S_1 \mid S_2\}$

(b) **Concaténation**

Soit $G = (V, \Sigma, R, S)$ avec :

- $V = V_1 \cup V_2 \cup \{S\}$ où $S \notin V_1 \cup V_2$ (renommage éventuel)
- $\Sigma = \Sigma_1 \cup \Sigma_2$
- $R = R_1 \cup R_2 \cup \{S \rightarrow S_1 S_2\}$

(c) **Opération étoile**

Soit $G = (V, \Sigma, R, S)$ avec :

- $V = V_1 \cup \{S\}$ où $S \notin V_1$ (renommage éventuel)
- $\Sigma = \Sigma_1$
- $R = R_1 \cup \{S \rightarrow S_1 S \mid \varepsilon\}$

Propriétés des langages algébriques

Propriétés de stabilité

- Contrairement à la classe des langages rationnels, la classe des langages algébriques n'est **pas stable** par **intersection** et **complémentation**
- Théorème

*L'intersection d'un langage **rationnel** et d'un langage **algébrique** est **algébrique***

Propriétés des langages algébriques

Lemme de l'étoile pour les langages algébriques

- Définition

Une grammaire algébrique $G = (V, \Sigma, R, S)$ est sous **forme normale de Chomsky** si chaque règle est de la forme :

$$A \rightarrow BC \text{ avec } B, C \in V - \{S\}$$

ou $A \rightarrow \sigma$ avec $\sigma \in \Sigma$

ou $A \rightarrow e$

- Théorème

Pour toute grammaire algébrique, il existe une grammaire sous forme normale de Chomsky équivalente

Propriétés des langages algébriques

Lemme de l'étoile pour les langages algébriques

- Théorème (lemme de la double étoile)

Soit L un langage algébrique

Il existe un nombre k , dépendant de L , tel que tout mot $z \in L$, $|z| \geq k$, peut être décomposé en $z = uvwx^i y$ avec :

(i) $|vwx| \leq k$

(ii) $|v| + |x| > 0$ (ie. $v \neq \varepsilon$ ou $x \neq \varepsilon$)

(iii) $uv^iwx^i y \in L, \forall i \geq 0$

(d'où l'appellation de double étoile : v^i et $x^i = v^*$ et x^*)

Propriétés des langages algébriques

Lemme de l'étoile pour les langages algébriques

- Lemme

Soit $G = (V, \Sigma, R, S)$ une grammaire algébrique sous forme normale de Chomsky

Soit $S \Rightarrow_G^* w$ une dérivation de $w \in \Sigma^*$ dont l'arbre de dérivation est noté T

Si la hauteur de T est n alors $|w| \leq 2^{n-1}$

- Corollaire

Soit $G = (V, \Sigma, R, S)$ une grammaire algébrique sous forme normale de Chomsky

Soit $S \Rightarrow_G^* w$ une dérivation de $w \in L(G)$

Si $|w| \geq 2^n$ alors l'arbre de dérivation est de hauteur $\geq n+1$

Propriétés des langages algébriques

Lemme de l'étoile pour les langages algébriques

- Exemple

Montrons que $L = \{ a^n b^n c^n \mid n \geq 0 \}$ est non algébrique

Supposons que L est algébrique

D'après le lemme de la double étoile, il existe une constante k , dépendant de L , telle que :

$\forall z \in L, |z| \geq k, z$ peut être décomposé en $z = uvwxy$ avec :

(i) $|vwx| \leq k$

(ii) $|v| + |x| > 0$ (au moins un des deux n'est pas le mot vide)

(iii) $uv^iwx^iy \in L, \forall i \geq 0$

Propriétés des langages algébriques

Lemme de l'étoile pour les langages algébriques

- Exemple

Considérons la chaîne particulière $z_0 = a^k b^k c^k$.

On a bien $z_0 \in L$ et $|z_0| = 3k \geq k$.

Les décompositions de $z_0 = uvwxy$ satisfaisant $|vwx| \leq k$ et $|v| + |x| > 0$ sont telles que :

- Soit l'une des sous-chaînes v ou x contient plus d'un type de symbole, de la forme $a^+ b^+$ ou $b^+ c^+$.
 $uv^i wx^i y$ avec $i > 1$ contient un a après un b ou un b après un c .

(par exemple $uv^2 wx^2 y = u aabb aabb w x x y$, si $v = aabb$)

donc la chaîne $uv^i wx^i y$ n'est plus de la forme $a^p b^q c^p$ avec $p \geq 0$,

donc $uv^i wx^i y \notin L$ pour $i > 1$.

- Soit v et x sont des sous-chaînes de a^k ou de b^k ou de c^k .

Comme au plus une des chaînes v ou x est vide, toute chaîne de la forme $uv^i wx^i y$ avec $i > 1$ est caractérisée par une augmentation de un ($v = \varepsilon$ ou $x = \varepsilon$) ou deux ($v \neq \varepsilon$ et $x \neq \varepsilon$) des trois types de terminaux.

donc pour $i > 1$, la chaîne $uv^i wx^i y$ est de la forme $a^p b^q c^r$ mais avec $p \neq q$ ou $q \neq r$.

donc $uv^i wx^i y \notin L$ pour $i > 1$.

- Pas d'autres possibilités pour v et x , les autres sous-chaînes u , w et y n'influencent pas.

Pour toutes les décompositions possibles de la chaîne z_0 il y a une contradiction.

Donc l'hypothèse est fautive $\Rightarrow L$ non algébrique.

Propriétés des langages algébriques

Preuve de non algébricité

- Pour montrer qu'un langage est **non algébrique**, on peut utiliser :
 - Le lemme de la double étoile
 - Les propriétés de stabilité de la classe des langages algébriques
 - Le théorème qui dit que l'intersection d'un langage algébrique et d'un langage rationnel est algébrique

Notion de décidabilité

- Une question est **décidable** s'il existe un **algorithme** (c'est-à-dire un processus **déterministe**) qui s'arrête avec une réponse (oui ou non) pour **chaque** entrée
- Une question est **indécidable** si un tel algorithme n'existe pas

Problèmes indécidables pour les langages algébriques

- Théorème

Les questions suivantes sont **décidables** :

- Étant donné une grammaire algébrique G et un mot w
est-ce que $w \in L(G)$?
- Étant donnée une grammaire algébrique G , est-ce que $L(G) = \emptyset$?

Les questions suivantes sont **indécidables** :

- Soit G une grammaire algébrique. Est-ce que $L(G) = \Sigma^*$?
- Soient G_1 et G_2 deux grammaires algébriques. Est-ce que $L(G_1) = L(G_2)$?
- Soient M_1 et M_2 deux automates à pile. Est-ce que $L(M_1) = L(M_2)$?
- Soit M un automate à pile. Trouver un automate à pile équivalent minimal en nombre d'états.