

Théorie des langages : THL

CM 5

Uli Fahrenberg

EPITA Rennes

S5 2023

Aperçu

Programme du cours

- 1 Langages rationnels, automates finis
- 3 Langages algébriques, grammaires hors-contexte, automates à pile
- 5 Parsage LL, partie 1
- 6 TP 1 : flex
- 7 **Parsage LL, partie 2**
- 8 TP 2 : parsage LL
- 9 Parsage LR
- 10 TP 3, 4 : flex & bison

La dernière fois : parsing

Problème de parsing

Pour une grammaire hors contexte G , construire un **algorithme de parsing** qui

- pour un mot w , décide si $w \in L(G)$,
- et dans le cas $w \in L(G)$, retourne l'arbre de dérivation.

- arbre de dérivation de $w \hat{=} \text{sémantique}$ de w

Nos algorithmes de parsing devrait

- pouvoir traiter des grammaires non-ambiguës
- avoir une complexité linéaire en taille d'entrée
- lire w de gauche à droite sans retour arrière

La dernière fois : parsage LL(1)

- approche descendante
- lire le mot w de gauche à droite / Left-to-right
 - sans passer à l'arrière
- construire une dérivation gauche / Leftmost
- en accordant, à chaque pas, le premier symbole de w avec le côté droit d'une production
 - donc avec lookahead 1

- parsage LL(k) : lookahead k / « fenêtre de k lexèmes »
- peu utilisé

La dernière fois : algorithmme LL(1)

- ① entrée : une grammaire hors contexte $G = (N, \Sigma, P, S)$
 - si-dessous, $V = N \cup \Sigma$
 - éliminer récursion à gauche dans G ; factoriser G à gauche
- ① calculer NULL
 - $\text{NULL} = \{A \in N \mid A \Rightarrow^* \varepsilon\}$
- ② construire la table FIRST
 - $\text{FIRST}(A) = \{a \in \Sigma \mid \exists w \in V^* : A \Rightarrow^* aw\}$
- ③ construire la table FOLLOW
 - $\text{FOLLOW}(A) = \{a \in \Sigma \mid \exists B \in N, \alpha, \beta \in V^* : B \Rightarrow^* \alpha A a \beta\}$
- ④ construire la TABLE de passage :
 - ① pour chaque production $X \rightarrow w$ (n) :
 - ① pour chaque $a \in \text{FIRST}(w)$: $\text{TABLE}(X, a) += \{n\}$
 - ② si $w \in \text{NULL}$ ou $w = \varepsilon$:
 - pour chaque $a \in \text{FOLLOW}(X)$: $\text{TABLE}(X, a) += \{n\}$

La dernière fois : LL(1)

Définition (8.5)

G est **LL(1)** si chaque $\text{TABLE}(A, a)$ contient **au maximum une** production.

La dernière fois : exemple

$$Z \rightarrow XYZ \quad (1)$$

$$| c \quad (2)$$

$$X \rightarrow a \quad (3)$$

$$| Y \quad (4)$$

$$Y \rightarrow b \quad (5)$$

$$| \varepsilon \quad (6)$$

La dernière fois : exemple

$$Z \rightarrow XYZ \quad (1)$$

$$| c \quad (2)$$

$$X \rightarrow a \quad (3)$$

$$| Y \quad (4)$$

$$Y \rightarrow b \quad (5)$$

$$| \varepsilon \quad (6)$$

$$\text{NULL} = \{X, Y\}$$

La dernière fois : exemple

$$Z \rightarrow XYZ \quad (1)$$

$$\quad | c \quad (2)$$

$$X \rightarrow a \quad (3)$$

$$\quad | Y \quad (4)$$

$$Y \rightarrow b \quad (5)$$

$$\quad | \varepsilon \quad (6)$$

$$\text{NULL} = \{X, Y\}$$

A	$\text{FIRST}(A)$
X	a, b
Y	b
Z	c, a, b

La dernière fois : exemple

$$Z \rightarrow XYZ \quad (1)$$

$$\quad | c \quad (2)$$

$$X \rightarrow a \quad (3)$$

$$\quad | Y \quad (4)$$

$$Y \rightarrow b \quad (5)$$

$$\quad | \varepsilon \quad (6)$$

$$\text{NULL} = \{X, Y\}$$

A	FIRST(A)
X	a, b
Y	b
Z	c, a, b

A	FOLLOW(A)
X	a, b, c
Y	a, b, c
Z	

La dernière fois : exemple

$$Z \rightarrow XYZ \quad (1)$$

$$\quad | c \quad (2)$$

$$X \rightarrow a \quad (3)$$

$$\quad | Y \quad (4)$$

$$Y \rightarrow b \quad (5)$$

$$\quad | \varepsilon \quad (6)$$

$$\text{NULL} = \{X, Y\}$$

A	FIRST(A)
X	a, b
Y	b
Z	c, a, b

A	FOLLOW(A)
X	a, b, c
Y	a, b, c
Z	

	a	b	c
X	3, 4	4	4
Y	6	5, 6	6
Z	1	1	1, 2

Exemples

Exemple (tableau)

$$S \rightarrow FS \quad (1)$$

$$| Q \quad (2)$$

$$| '(S)' S \quad (3)$$

$$F \rightarrow '!' \quad (4)$$

$$Q \rightarrow '?' \quad (5)$$

« Une session est une séquence de faits suivi par une question ;
sous-sessions sont permis »

Exemple (tableau)

$$Z \rightarrow S\$ \quad (1)$$

$$S \rightarrow LQ \quad (2)$$

$$| '(S)' S \quad (3)$$

$$L \rightarrow FL \quad (4)$$

$$| \varepsilon \quad (5)$$

$$F \rightarrow '!' \quad (6)$$

$$Q \rightarrow '?' \quad (7)$$

Plus ça change, ...

Implémentation

Grammaire :

$$S \rightarrow F \quad (1)$$

$$| '(S '+' F)' \quad (2)$$

$$F \rightarrow 'a' \quad (3)$$

Simple parseur en Python :

`parse.py`

Bonus : langages non-rationnels

Motifs répétitifs

- Existent-ils des langages non-rationnels ?
- Le langage $\{a^n b^n \mid n \geq 0\}$ est-il rationnel ?
- Le langage des expressions arithmétiques est-il rationnel ?

Lemme de l'étoile

- 1 Soit $A = (\Sigma, Q, Q_0, F, \delta)$ un automate fini avec k états.
- 2 Soit $x \in L(A)$ un mot de longueur $|x| = k$ (si il existe); écrivons $x = a_1 \dots a_k$.
- 3 Alors on a un calcul réussi $s_1 \xrightarrow{a_1} s_2 \xrightarrow{a_2} \dots \xrightarrow{a_k} s_{k+1}$ dans A .
- 4 Ce calcul utilise $k + 1$ états, alors un état de A a été utilisé **deux fois**. (Principe des tiroirs.)
- 5 Soient donc $i < j$ tel que $s_i = s_j$: la chaîne $s_i \rightsquigarrow s_j$ est une **boucle**.
- 6 Alors $s_1 \xrightarrow{a_1} \dots \xrightarrow{a_{i-1}} s_i \xrightarrow{a_j} s_{j+1} \rightarrow \dots \rightarrow s_{k+1}$ est aussi un calcul réussi, avec étiquette $a_1 \dots a_{i-1} a_j \dots a_k$.
- 7 En écrivant $u = a_1 \dots a_{i-1}$, $v = a_i \dots a_{j-1}$ et $w = a_j \dots a_k$ on trouve que $L(uv^*w) \subseteq L(A)$.

Lemme de l'étoile

Théorème (4.25)

Soit L un langage rationnel. Il existe $k \geq 0$ tel que tout $x \in L$ avec longueur $|x| \geq k$ peut s'écrire $x = uvw$ avec $|uv| \leq k$, $|v| \geq 1$ et $L(uv^*w) \subseteq L$.

- aussi **lemme de pompage**
- note $\exists k : \forall x : \exists u, v, w$
- démonstration par quelques petites modifications de l'argument précédent

Corollaire

Théorème (rappel)

Soit L un langage rationnel. Il existe $k \geq 0$ tel que tout $x \in L$ avec longueur $|x| \geq k$ peut s'écrire $x = uvw$ avec $|uv| \leq k$, $|v| \geq 1$ et $L(uv^*w) \subseteq L$.

Corollaire

Le langage $\{a^n b^n \mid n \geq 0\}$ n'est pas rationnel.

Démonstration.

- 1 Supposons par l'absurde que L soit rationnel.
- 2 Soit k comme fourni par la lemme d'étoile.
- 3 Soit $x = a^k b^k$, alors $x = uvw$ avec $|uv| \leq k$ et $|v| \geq 1$.
- 4 Donc $u = a^i$, $v = a^j$ et $w = a^{k-i-j} b^k$ pour un $j \geq 1$.
- 5 On a $uw \in L(uv^*w)$ mais $uw \notin L$, contradiction !

Exercice

Théorème (rappel)

*Soit L un langage rationnel. Il existe $k \geq 0$ tel que tout $x \in L$ avec longueur $|x| \geq k$ peut s'écrire $x = uvw$ avec $|uv| \leq k$, $|v| \geq 1$ et $L(uv^*w) \subseteq L$.*

Montrer que le langage $\{ww \mid w \in \{a, b\}^*\}$ n'est pas rationnel.

Les automates finis sont décidables

Théorème (4.27)

Il existe un algorithme qui, pour A un automate fini, décide si $L(A)$ est vide, fini ou infini.

Démonstration.

Soit k le nombre d'états de A .

- 1 $L(A)$ est non-vide ssi il existe $w \in L(A)$ avec longueur $|w| < k$.
- 2 $L(A)$ est infini ssi il existe $w \in L(A)$ avec $k \leq |w| < 2k$.

(le reste sur tableau)

The image features a central graphic consisting of several concentric circles. The innermost circle is a solid dark blue. Surrounding it are several rings of varying shades of red, from a deep, dark red to a bright, vibrant red. The text "That's all Folks!" is written in a white, elegant cursive font, slanted slightly upwards from left to right, and is positioned across the middle of the concentric circles.

That's all Folks!