

Grammaire Hors-Contexte

Quadruplet $G = (V_t, V_n, Z, P)$ tel que :

- V_t : *vocabulaire terminal* (les *lexèmes*)
ensemble fini de symboles, notés en minuscules
- V_n : *vocabulaire non-terminal*
ensemble fini de symboles, notés en majuscules ($V_t \cap V_n = \emptyset$)
- $Z \in V_n$: *axiome*
- P : ensemble des *règles* (ou *productions*)
 $P \subseteq V_n \times (V_t \cup V_n)^*$
Les éléments (X, α) de P seront notés $X \rightarrow \alpha$.

Dérivations

$G = (V_t, V_n, Z, P)$ une grammaire hors-contexte, $w, w' \in (V_t \cup V_n)^*$.

- w' est un *dérivé direct* par G de w , noté $w \Rightarrow_G w'$ ssi :
il existe $X \in V_n$, il existe $u, t, v \in (V_t \cup V_n)^*$ tels que

$$w = uXv \text{ et } w' = utv \text{ et } X \rightarrow t \in P.$$

- w' est un *dérivé* par G de w , noté $w \Rightarrow_G^* w'$, ssi :
il existe $w_0, w_1, \dots, w_n \in (V_t \cup V_n)^*$ tels que

$$w_0 = w, w_n = w' \text{ et pour tout } i \ w_{i+1} \text{ est un dérivé direct de } w_i.$$

Remarque : $\Rightarrow_G^*$ est la fermeture transitive de $\Rightarrow_G$.

Langages hors-contextes

$G = (V_t, V_n, Z, P)$ une grammaire hors-contexte.

Le *langage défini* par G (ou *reconnu* par G) est l'ensemble $L(G)$ tel que :

$$L(G) = \{w \in V_t^* \mid Z \Rightarrow_G^* w\}$$

Un langage L est dit *hors-contexte* s'il existe une grammaire hors-contexte qui le reconnaît.

Remarque : Tout langage régulier est un langage hors-contexte, il existe des langages hors-contexte qui ne sont pas réguliers.

Arbres de dérivation

Soit $G = (V_t, V_n, Z, P)$ une grammaire et w un mot de $L(G)$.

On appelle *arbre de dérivation* (ou *arbre syntaxique*) de w dans G tout arbre n -aire A dont les noeuds sont des éléments de $(V_t \cup V_n)$ et tel que :

- la racine de A est Z (l'axiome de G) ;
- les feuilles de A sont des éléments de $V_t \cup \{\varepsilon\}$ et la séquence gauche-droite des feuilles de A est égale à w ;
- les noeuds non feuilles de A sont des éléments de V_n et si un noeud non feuille X a pour fils $u_1, u_2, \dots, u_n$ dans A alors la règle $X \rightarrow u_1.u_2 \dots u_n$ doit appartenir à P .

A tout mot de $L(G)$ on peut associer un arbre de dérivation.

Si cet arbre est **unique** alors la grammaire est dite **non ambiguë**.

Langages hors-contexte et automates

- langage réguliers = $a^*.b^*$
⇒ langage reconnaissable par un **automate d'état fini**
- langages hors-contexte = $a^n.b^n, n \geq 0$
⇒ il faut ajouter une **mémoire non bornée** à l'automate ...
⇒ il suffit de pouvoir gérer cette mémoire comme une **pile**

Fonctionnement intuitif d'un **automate à pile** :

- un ensemble fini d'états Q , un vocabulaire de pile Γ
- une *configuration* = $(q, w, \alpha) \in Q \times V^* \times \Gamma^*$
- en fonction de l'état courant q , du sommet de pile α et du symbole d'entrée v
 - ▶ lecture éventuelle de v
 - ▶ modification éventuelle du sommet de pile (empiler/dépiler) α est remplacé par β (avec $\beta \in \Gamma^*$)

Une séquence ω est reconnue ssi l'état atteint est *accepteur*.

Exemple

Proposer un automate à pile qui reconnaît le langage

$$\{a^n.b^n.c \mid n \geq 0\}$$

Quelques propriétés (importantes en pratiques !)

- ① tout langage **régulier** est reconnu par un automate **d'état fini** (et réciproquement)
- ② tout langage **hors-contexte** est reconnu par un automate **à pile** (et réciproquement)
- ③ A est un automate d'état fini, il existe un automate A' tq :
 - ▶ A' est un automate d'état fini **déterministe**
 - ▶ A et A' reconnaissent le **même** langage
- ④ tout langage régulier est reconnu par un automate **déterministe**
- ⑤ la propriété 3 est **fausse** pour les automates à pile
- ⑥ il existe des langages hors-contexte **non reconnus** par un automate à pile **déterministe**

Analyse Syntaxique

Soit $G = (V_t, V_n, Z, P)$ une grammaire hors-contexte,
soit ω un séquence de V_t^* .

Analyse syntaxique = déterminer si $\omega \in L(G)$?

Contraintes pratiques :

- algorithme **linéaire** en fonction de $|\omega|$
- accès **séquentiel** à ω , de gauche à droite

⇒ possible uniquement pour un **sous-ensemble strict** des langages hors-contexte

⇒ celui qui est reconnaissable par un automate à pile **déterministe** !

Problèmes posés :

- Est-ce que le **langage** considéré appartient à cette classe ?
- Si oui, comment construire (efficacement) un analyseur (efficace) ?

⇒ réponse en fonction de la **structure** de la **grammaire** considérée !

Dans la suite ...

- on considère d'abord une technique **d'analyse descendante** :
 - ▶ produire ω à partir de Z
 - ▶ produire une dérivation *gauche* $Z \Rightarrow_G^* \omega$
- on cherche à caractériser :
 - ▶ une classe de grammaire pour laquelle une analyse syntaxique **déterministe** est possible ;
 - ▶ une **condition suffisante** pour décider si une grammaire appartient à cette classe

$\Rightarrow$ **grammaires LL**

Exemple 1

L1 défini par la grammaire suivante

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

$$Z \rightarrow bY \quad (2)$$

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

$$X \rightarrow d \quad (4)$$

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

$$Y \rightarrow bY \quad (6)$$

$$Y \rightarrow cYX \quad (7)$$

Est-ce que abbbdc appartient à L1 ?

Est-ce que bbae appartient à L1 ?

Est-ce que be appartient à L1 ?

Exemple 2

L2 défini par la grammaire suivante

$$Z \rightarrow aX \quad (8)$$

$$X \rightarrow bY \quad (9)$$

$$X \rightarrow bT \quad (10)$$

$$Y \rightarrow c \quad (11)$$

$$T \rightarrow d \quad (12)$$

Est-ce que abd appartient à L2 ?

Exemple 3

L3 défini par la grammaire suivante

$$Z \rightarrow S\# \quad (13)$$

$$S \rightarrow XaY \quad (14)$$

$$X \rightarrow W \quad (15)$$

$$X \rightarrow T \quad (16)$$

$$W \rightarrow bc \quad (17)$$

$$T \rightarrow ac \quad (18)$$

$$Y \rightarrow eY \quad (19)$$

$$Y \rightarrow f \quad (20)$$

$$Y \rightarrow \varepsilon \quad (21)$$

Est-ce que $aceef\#$ appartient à L3?

Premiers, Suivants

Soit $G = (V_t, V_n, Z, P)$ une grammaire hors-contexte.

- soit $\alpha \in (V_t \cup V_n)^*$, le prédicat **Vide**(α) vaut vrai ssi ε peut être dérivé de α par G :

$$\mathbf{Vide}(\alpha) \equiv \alpha \Rightarrow_G^* \varepsilon$$

- soit $\alpha \in (V_t \cup V_n)^*$, **Premiers**(α) est l'ensemble des symboles terminaux qui peuvent débiter une dérivation de α par G :

$$\mathbf{Premier}(\alpha) = \{a \in V_t \mid \alpha \Rightarrow_G^* a\beta\}$$

- soit $X \in V_n$, **Suivants**(X) est l'ensemble des symboles terminaux qui peuvent suivre une occurrence de X dans une dérivation de Z par G :

$$\mathbf{Suivants}(X) = \{a \in V_t \mid Z \Rightarrow_G^* \alpha X a \beta\}$$

Directeurs

soit $X \rightarrow u_1.u_2 \dots u_n$ une règle de P , avec $u_i \in (V_t \cup V_n)$.

Directeurs($X \rightarrow u_1.u_2 \dots u_n$) est l'ensemble des symboles terminaux qui peuvent débiter une dérivation par cette règle :

$$\begin{aligned} \mathbf{Directeurs}(X \rightarrow u_1.u_2 \dots u_n) = \\ (\bigcup_{i \in V_i} \mathbf{Premiers}(u_i)) \\ \cup (\text{si } \mathbf{Vide}(u_1 \dots u_n) \text{ alors } \mathbf{Suivants}(X) \text{ sinon } \emptyset) \end{aligned}$$

avec $V_i = \{i \mid \mathbf{Vide}(u_1 \dots u_{i-1})\}$.

Grammaire LL(1)

Une grammaire hors-contexte $G = (V_t, V_n, Z, P)$ est dite $LL(1)$ si et seulement si l'ensemble des règles de P définissant un même symbole non-terminal ont des directeurs disjoints :

$$\forall X \in V_n. \forall X \rightarrow \alpha, X \rightarrow \beta \in P.$$

$$\mathbf{Directeur}(X \rightarrow \alpha) \cap \mathbf{Directeur}(X \rightarrow \beta) = \emptyset$$

Un langage hors-contexte est dit $LL(1)$ si et seulement si il existe une grammaire $LL(1)$ qui le reconnaît.

L'ensemble des langages $LL(1)$ est **strictement inclus** dans l'ensemble des langages hors-contexte reconnus par un automate à pile **déterministe**

Exemple

$$Z \rightarrow S\# \quad (22)$$

$$S \rightarrow Xa \quad (23)$$

$$S \rightarrow \varepsilon \quad (24)$$

$$X \rightarrow bX \quad (25)$$

$$(26)$$

$$\text{Premiers}(S) = \text{Premiers}(X) = \{b\}$$

$$\text{Vide}(S) = \text{vrai}$$

$$\text{Suivants}(S) = \{\#\}$$

$$\text{Suivant}(X) = \text{Suivants}(X) \cup \{a\} = \{a\}$$

$$\text{Directeurs}(Z \rightarrow S\#) = \text{Premiers}(S) \cup \{\#\} \quad (\text{car Vide}(S))$$

$$\text{Directeurs}(S \rightarrow Xa) = \text{Premiers}(X) = \{b\}$$

$$\text{Directeurs}(S \rightarrow \varepsilon) = \text{Suivants}(S) = \{\#\}$$

Rendre une grammaire LL(1) ?

Etant donnée une grammaire hors-contexte G , construire G' telle que :

- $L(G') = L(G)$
- G' est LL(1)

Problème :

- ce n'est pas toujours possible !
(langages LL(1) $\subset$ langages hors-contexte)
- savoir si cela est possible est **indécidable** ...

On propose donc des “heuristiques” pour construire G' , mais :

- il n'est pas certain que la grammaire obtenue soit LL(1) ...
- si elle ne l'est pas il faut peut-être continuer à chercher ...

Heuristique 1 : factorisation

Si G contient deux règles de la forme :

$$X \rightarrow a\alpha$$

$$X \rightarrow a\beta$$

Alors on peut construire G' :

$$X \rightarrow aY$$

$$Y \rightarrow \alpha$$

$$Y \rightarrow \beta$$

$\Rightarrow G'$ est LL(1) si $\text{Premier}(\alpha) \cap \text{Premier}(\beta) = \emptyset$

Heuristique 2 : élimination de la récursivité à gauche

Si G contient deux règles de la forme :

$$X \rightarrow X\alpha$$

$$X \rightarrow \beta$$

Alors on peut construire G' :

$$X \rightarrow \beta Y$$

$$Y \rightarrow \alpha Y$$

$$Y \rightarrow \varepsilon$$

$\Rightarrow G'$ est LL(1) si $\text{Premier}(\alpha) \cap \text{Suivants}(X) = \emptyset$

Analyseur LL(1) basé sur une “table de prédiction”

$$\begin{array}{l|l} Z \rightarrow S\$ & \{1, 0\} \\ S \rightarrow AB & \{1, 0\} \\ A \rightarrow 1A0 & \{1\} \\ A \rightarrow \varepsilon & \{0\} \end{array} \quad \begin{array}{l} B \rightarrow 0Y & \{0\} \\ Y \rightarrow B & \{0\} \\ Y \rightarrow \varepsilon & \{\$ \} \end{array}$$

$$L(G) = \{1^n 0^n 0^m \mid 0 \leq n \text{ et } 0 < m\}$$

L'automate de l'analyseur :

	0	1	\$
Z	$Z \rightarrow S\$$	$Z \rightarrow S\$$	
S	$S \rightarrow AB$	$S \rightarrow AB$	
A	$A \rightarrow \varepsilon$	$A \rightarrow 1A0$	
B	$B \rightarrow 0Y$		
Y	$Y \rightarrow B$		$Y \rightarrow \varepsilon$

Analyseur LL(1) basé sur des procédures récursives

$Z \rightarrow S\$ \quad \{1, 0\}$

Rec_Z :
 init_sequence() ; si symbole_courant() = "1" ou symbole_courant() = "0" alors Rec_S sinon erreur() ;
 Rec_terminal(\$)

$S \rightarrow AB \quad \{1, 0\}$

Rec_S :
 si symbole_courant() = "1" ou symbole_courant() = "0" alors Rec_A ; Rec_B ; sinon erreur()

$A \rightarrow 1A0 \quad \{1\} \quad | \quad A \rightarrow \varepsilon \quad \{0\}$

Rec_A :
 si symbole_courant() = "1" alors
 Rec_terminal("1") ; Rec_A ; Rec_terminal("0") ;
 sinon si symbole_courant() = "0" alors
 rien ;
 sinon erreur()

$B \rightarrow 0Y \quad \{0\}$

Rec_B :
 si symbole_courant() = "0" alors Rec_terminal("0") ; Rec_Y ;
 sinon erreur()

$Y \rightarrow B \quad \{0\} \quad | \quad Y \rightarrow \varepsilon \quad \{\$ \}$

Rec_Y :
 si symbole_courant() = "0" alors
 Rec_B ;
 sinon si symbole_courant() = "\$" alors
 rien ;
 sinon erreur()