

# Grammaires

# Sommaire

1. Définitions
2. Dérivations
3. Classification des grammaires
4. Représentations des grammaires hors contexte
  1. Notation BNF
  2. Diagrammes de conway
  3. Arbres de dérivation

# 1-définitions

Une **grammaire formelle**, appelée aussi **grammaire de Chomsky**,  $G$  est une description de la forme des symboles et des phrases d'un langage noté  $L(G)$ . Elle est définie par un quadruplet  $G = (V_T, V_N, S, R)$  où :

- $V_T$  est un ensemble fini non vide : le **vocabulaire terminal** ou **alphabet** ;  
 $L(G) \subseteq V_T^*$
- $V_N$  est un ensemble fini non vide : le **vocabulaire non terminal** (on parle aussi de **variable** ou de **catégorie syntaxique**) ; On a  $V_T \cap V_N = \emptyset$  et on note  $V = V_T \cup V_N$  le **vocabulaire** de la grammaire ;
- $S \in V_N$  est un symbole non terminal particulier appelé **l'axiome** ;
- $R$  est un ensemble de **règles**, appelées **règles de production** (ou **règles de réécriture**), de la forme  $\alpha \rightarrow \beta$  avec  $\alpha \in V^+$  et  $\beta \in V^*$

# Exemples

- $G_0 = (\{0, 1\}, \{S, X\}, S, R)$  avec  $R$  :
  - $R1 : S \rightarrow 0X1$
  - $R2 : 0X \rightarrow 00X1$
  - $R3 : X \rightarrow \varepsilon$
- $G_1 = (\{0, 1\}, \{S, X\}, S, R)$  avec :
  - $R = \{S \rightarrow 0X1 ; 0X \rightarrow 00X1 ; 0X \rightarrow 001\}$
  - ou  $R = \{S \rightarrow 0X1 ; 0X \rightarrow 00X1 \mid 001\}$  (équivalent)
- $G_2 = (\{0, 1\}, \{S\}, S, R)$  avec :
  - $R = \{S \rightarrow 0S1 \mid 01\}$
- $G_3 = (\{0, 1\}, \{S, X\}, S, R)$  avec :
  - $R = \{S \rightarrow 0S \mid 0X ; X \rightarrow 1X \mid 1\}$

# Dérivations

- Soit  $G = (V_T, V_N, S, R)$  une grammaire.
- On appelle **dérivation de longueur  $n$**  ( $n \in \mathbb{N}$ ) toute suite  $s = u_0, \dots, u_n$  de chaînes de  $V^*$  telle que  $u_0 =_G \Rightarrow u_1$  et ... et  $u_{n-1} =_G \Rightarrow u_n$  (ce que l'on abrège par  $u_0 =_G \Rightarrow \dots =_G \Rightarrow u_n$ )
- $a =_n \Rightarrow b$  désigne une dérivation de longueur  $n$ .
- $a =^* \Rightarrow b$  désigne une dérivation de longueur quelconque. Autrement dit,  $=^* \Rightarrow$  est la fermeture réflexive et transitive de  $=_G \Rightarrow$ .
- $a =_{+} \Rightarrow b$  désigne une dérivation de longueur supérieure à 1. Autrement dit,  $=_{+} \Rightarrow$  est la fermeture transitive de  $=_G \Rightarrow$ .
- Si  $a =^* \Rightarrow b$ , on dit alors que  $a$  **engendre**  $b$  ou, symétriquement, que  $b$  **dérive de**  $a$ . Si de plus  $a =_{+} \Rightarrow b$ , on dit "engendre" (resp. "dérive") "de façon non triviale".

- Soit  $G = (V_T, V_N, S, R)$  une grammaire :
- Une chaîne  $a$  est une forme sententielle (proto-phrase) pour la grammaire  $G$  si et seulement si  $S \xRightarrow{*} a$ .
- Le langage **engendré** par  $G$  est l'ensemble des chaînes de symboles terminaux que l'on peut dériver à partir de l'axiome  $S$  :  
$$L(G) = \{x \in V_T^* \mid S \xRightarrow{+} x\}.$$
- Deux grammaires  $G_1$  et  $G_2$  sont dites équivalentes si  $L(G_1) = L(G_2)$ .

# 4. Classification des grammaires

- **Type 0 : sans contraintes**

Les règles sont de la forme:

- -  $a \rightarrow b$  avec  $a \in V^+$  et  $b \in V^*$ .

- **Type 1 (contextuelle, context sensitive, sensible au contexte):** -  $a \rightarrow b \mid |a| \leq |b|$ .


- -  $aAb \rightarrow aBb$  avec  $a, b \in V^*$ ,  $A \in V_N$  et  $B \in V^+$  tel que  $|B| \geq 1$  (c'est-à-dire que  $A$  peut être remplacé par  $B$  dans le contexte  $aAb$ ).

l'axiome, s'il n'est pas en partie droite d'une autre règle que celle qui le définit, peut engendrer  $\varepsilon$ . Cette exception est aussi valable pour les types suivants

- **Type 2 : hors-contexte**  
(context free,  
algébrique)
- Une grammaire est de type 2 si elle est de type 1 et si toutes ces productions ont la forme suivante:
  - $A \rightarrow a$  avec  $A \in V_N$  et  $a \in V^+$ .
- **Type 3 : linéaires**  
(régulières)  
[à] droite (resp. [à] gauche):
- Une grammaire est de type 3 si elle est de type 2 et elle est soit linéaire à droite soit linéaire à gauche.
  - $A \rightarrow x_1 \mid x_2 B$  (resp.  $A \rightarrow x_1 \mid B x_2$ ) avec  $A, B \in V_N$  et  $x_1 \in V_T^+$ ,  $x_2 \in V_T^*$ .


# Exemples

- règles  $S \rightarrow OS \mid 1S \mid \varepsilon$  est linéaire droite.
- $G_0$  et  $G_4$  sont de type 0,
- $G_1$  est de type 1,  $G_2$  est de type 2 et  $G_3$  est de type 3.



## 4-3 Arbres de dérivation

Toute phrase du langage  $L(G)$  peut être obtenue après un ensemble de dérivation à partir de l'axiome:  $S \Rightarrow^+ a$  ( $a \in L(G) \subseteq V_T^*$ ). Une telle dérivation peut être aussi représentée par un arbre de dérivation (appelé aussi « arbre syntaxique » ou « arbre d'analyse », exemple : Par exemple, en considérant les règles  $R1 : A \rightarrow BaC$ ,  $R2 : B \rightarrow b$  et  $R3 : C \rightarrow c$ , à la dérivation  $A \Rightarrow^{R1} BaC \Rightarrow^{R2} baC \Rightarrow^{R3} bac$  correspond l'arbre suivant :



la représentation des dérivations sous forme d'arbres ne mémorise pas l'ordre dans lequel les règles sont appliquées. Par exemple, l'arbre ci-dessus correspond également à la dérivation  $A \Rightarrow^{R1} BaC \Rightarrow^{R3} Bac \Rightarrow^{R2} bac$ .

Remarques: La racine de l'arbre est l'axiome. Les feuilles sont les symboles terminaux de la phrase.

Une grammaire est dite ambiguë si au moins une phrase de son langage a plus d'un arbre de dérivation.

## Exemple



soit la grammaire  $G_6 = (\{0, 1, 2, 3, 4, 5, 6, 7, 8, 9, +, *\}, \{S, Ch\}, S, R)$ ,  
avec R :

$S \rightarrow Ch$

$Ch \rightarrow Ch + Ch \mid Ch * Ch$

$Ch \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$

Par cette grammaire, nous pouvons obtenir pour le mot "3\*1+5"  
les arbres de dérivation suivants :




# 5- représentation des grammaires

- **5.1 Notation BNF**
- Elle est particulièrement utile pour analyser un langage défini par une grammaire hors-contexte
- Les symboles terminaux sont encadrés par des guillemets ("..." ou <<...>>), les symboles non terminaux ne sont pas distingués
- L'axiome est la partie gauche de la première règle énoncée. La disjonction est notée par une barre verticale ( | ). La flèche des règles est remplacée par le signe "::=". Par exemple, le tableau suivant illustre la forme BNF pour les règles  $\{S \rightarrow bA ; A \rightarrow aA ; A \rightarrow a\}$ .
  - $S ::= "b"A$
  - $A ::= "a"A \mid "a"$

## 5.2 les diagrammes de conway

- Elle décrit graphiquement les grammaires hors-contexte
- La partie gauche des règles est notée à gauche du schéma. Les symboles terminaux sont écrits dans des cercles et les symboles non terminaux sont écrits dans des rectangles.



## ***Exercices et tests :***

**Exercice 5.1.** Pour chacune des grammaires suivantes :

1. Les écrire sous forme BNF

2. Donner les arbres de dérivation associés à certaines phrases de chaque grammaire. dans le cas où la grammaire est de type 2 ou 3. Les représenter à l'aide des diagrammes de Conway

Gex1 = ( $\{a,b,c\}$ ,  $\{S\}$ ,  $S$ ,  $\{S \rightarrow aSbSa \mid c\}$ )

Gex2 = ( $\{a,b\}$ ,  $\{S,A\}$ ,  $S$ ,  $\{S \rightarrow Aa \mid bA ; A \rightarrow Sa \mid bS\}$ )

**Exercice 5.2.** Soit la grammaire ( $\{0,1,2,3,4,5,6,7,8,9,;, -, +\}$ ,  $\{S, \text{Exp}, \text{Ch}\}$ ,  $S$ ,  $R$ ) définie par les règles suivantes :

•  $S \rightarrow \text{Exp} ; S \mid \text{Exp}$

•  $\text{Exp} \rightarrow \text{Exp} + \text{Exp} \mid \text{Exp} - \text{Exp} \mid \text{Ch}$

•  $\text{Ch} \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$

1. Écrire ces règles sous forme BNF

2. Donner les diagrammes de Conway correspondants