

2.0 Rappels sur les grammaires syntagmatiques

Grammaire formelle Pour définir une grammaire formelle, il faut définir

- un alphabet *terminal* (X),
- un alphabet *non terminal* disjoint (V), comprenant l'axiome $S \in V$,
- un ensemble de couples de $(X \cup V)^*V(X \cup V)^* \times (X \cup V)^*$, les règles de production.

Principe de réécriture Les grammaires formelles constituent un cas particulier de *système de réécriture* (ensemble de règles de réécriture).

Une règle de réécriture de la forme $r \rightarrow r'$ s'applique à l'objet syntaxique t si celui-ci contient une instance du membre gauche r , c'est-à-dire un sous-objet que l'on peut identifier à r . L'objet t se réécrit alors en un nouvel objet t' , obtenu en remplaçant l'instance de r par l'instance du membre droit r' correspondante. Notation : $t \rightarrow t'$.

Dérivation Pour les grammaires formelles, on définit ainsi la réécriture (ou dérivation) immédiate (pour une règle $r : A \rightarrow u$) : $f \xrightarrow{r} g$ ssi $\exists v, w$ t.q. $f = vAw$ et $g = vuw$

La *dérivation* est définie comme la fermeture de la dérivation immédiate :

$$f \xrightarrow{G^*} g \text{ ssi } f = g, \text{ ou } \exists f_1 = f, f_2, \dots, f_n = g, \exists r_i \in P \text{ t.q. } f_{i-1} \xrightarrow{r_i} f_i$$

Proto-mot, langage engendré Un mot sur $(X \cup V)^*$ obtenu au cours d'une dérivation et contenant au moins un symbole non terminal est appelé *proto-mot*. L'ensemble des mots (sur X^*) engendrés à partir de l'axiome constitue le *langage engendré* par la grammaire.

Dérivations multiples En général, la suite de réécritures immédiates qui conduit de l'axiome à un mot donné u n'est pas unique. On distingue parmi les suites possibles la *dérivation gauche*, définie de telle sorte que le non-terminal réécrit à chaque étape est le premier non-terminal du proto-mot. Une grammaire telle que pour un mot donné il existe plusieurs dérivations gauches distinctes est une grammaire *ambigüe*.

Pouvoir expressif On peut distinguer des sous-classes de grammaires formelles, sur la base de la forme des règles de production. Ces classes de grammaires définissent à leur tour des classes de langages formels. Chomsky a proposé une hiérarchie de classes de grammaires/langages, dont les classes sont incluses les unes dans les autres.

Langages	type	règles	machine
récurivement énumérables	0	<i>pas de contraintes</i>	Machine de Turing
contextuels	1	$\alpha A \beta \rightarrow \alpha \gamma \beta$, avec $A \in V, \alpha, \beta, \gamma \in (X \cup V)^*, \gamma \neq \varepsilon$	Automates à pile linéairement bornée
algébriques	2	$A \rightarrow \gamma$, avec $A \in V, \gamma \in (X \cup V)^*$	Automates à pile
rationnels	3	$A \rightarrow Ba, A \rightarrow a$, avec $A, B \in V, a \in X$	Automates à nombre fini d'états

Arbre de dérivation Pour les **grammaires algébriques**, on peut représenter l'ensemble des dérivations équivalentes par un *arbre de dérivation*.

$\mathcal{G}_0 =$	$S \rightarrow TZ$ $T \rightarrow 0T1C$ $\quad \mid \varepsilon$ $C1 \rightarrow 1C$ $CZ \rightarrow Z2$ $1Z \rightarrow 1$	\underline{S} \underline{TZ} $0\underline{T}1CZ$ $00\underline{T}1C1CZ$ $00\varepsilon 1\underline{C}1CZ$ $0011\underline{CZ}$ $0011\underline{CZ}2$ $001\underline{1Z}22$ 001122	\underline{S} \underline{TZ} $0\underline{T}1\underline{CZ}$ $0\underline{T}1Z2$ $00\underline{T}1C1Z2$ $00\varepsilon 1\underline{C}1Z2$ $0011\underline{CZ}2$ $001\underline{1Z}22$ 001122	$L_{\mathcal{G}_0} = 0^i 1^i 2^i$
-------------------	--	---	--	-----------------------------------

$$\mathcal{G}_1 = \left\langle \{ \text{jean}, \text{dort} \}, \{ Np, SN, SV, V, S \}, S, \left\{ \begin{array}{l} S \rightarrow SN \text{ } SV \\ SN \rightarrow Np \\ SV \rightarrow V \\ Np \rightarrow \text{jean} \\ V \rightarrow \text{dort} \end{array} \right\} \right\rangle$$

$$\mathcal{G}_2 = \langle \{ (,) \}, \{ S \}, S, \{ S \rightarrow \varepsilon \mid (S)S \} \rangle$$

$$\mathcal{G}_3 = E \rightarrow E + T \mid T, T \rightarrow T \times F \mid F, F \rightarrow (E) \mid a$$

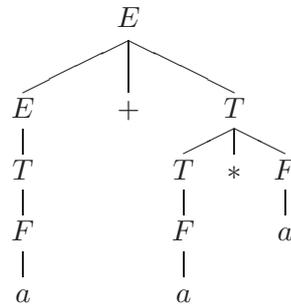
Voici un exemple de dérivation du mot $a + a * a$ par la grammaire \mathcal{G}_2 (8 étapes) :

$$E \Rightarrow E+T \Rightarrow E+T*F \Rightarrow T+T*F \Rightarrow T+F*F \Rightarrow T+a*F \Rightarrow F+a*F \Rightarrow a+a*F \Rightarrow a+a*a$$

Dérivation gauche :

$$E \Rightarrow E + T \Rightarrow T + T \Rightarrow F + T \Rightarrow a + T \Rightarrow a + T * F \Rightarrow a + F * F \Rightarrow a + a * F \Rightarrow a + a * a$$

Factorisation par un arbre de dérivation :



$$\mathcal{G}'_2 = \langle \{ E \}, \{ a, +, \times \}, E, \{ E \rightarrow E + E \mid E \times E \mid a \} \rangle$$

Deux arbres \neq pour $a + a * a$:

