

Grammaires et Hiérarchie de Chomsky

Grammaires : Séance 1

Marie-Laure Potet

Grenoble INP-Ensimag

2020-2021

Summary

- 1 Introduction
- 2 Grammaires
- 3 Langage associé à une grammaire
- 4 Hiérarchie de Chomsky

Description de langages

Rappels :

- V un vocabulaire (ensemble fini de symboles), $L \subseteq V^*$ un langage.
- **Langages réguliers** : langages reconnus par automate ayant un nombre fini d'états, langages descriptibles par expressions régulières (union, concaténation, itération)
- Certains langages ne sont pas réguliers : $a^n b^n$. Preuve en montrant qu'il n'existe pas d'automate (lemme de l'étoile)
- Problème d'expressivité : peut-on décrire systématiquement plus de langages ?
 - ✓ **Les grammaires**
- **Le langage de programmation idéal ça serait quoi ?**

Intérêt d'un formalisme de description

- Permet de caractériser une classe de langages. Exemples : les langages reconnus par automates d'état fini.
- Permet de donner des algorithmes agissant sur les formalismes. Exemple : algorithme de détermination.
- Permet d'étudier la décidabilité de propriétés sur les formalismes.
 - $P(x)$ Décidable : il existe un algorithme permettant de répondre oui/non à la question " $P(x)$ est vrai" pour tout x .
 - Indécidable : il n'existe pas d'algorithme

✓ La hiérarchie de Chomsky. Expressivité versus Décidabilité et Complexité.

Exemples de problèmes décidables/indécidables sur les langages réguliers ? sur les programmes ?

Summary

- 1 Introduction
- 2 Grammaires**
- 3 Langage associé à une grammaire
- 4 Hiérarchie de Chomsky

Grammaires : qu'est ce que c'est ?

✓ Similaire à la grammaire d'une langue. Exemple grammaire de l'anglais en français.

- **Un vocabulaire terminal** : ce qui constituera les mots (les phrases) du langage. Exemple : le vocabulaire de l'anglais.
- **Un vocabulaire non terminal** : ce qui permet de parler de la construction des mots (phrases). Les catégories grammaticales.
- **Des règles** permettant de produire les mots (phrases) du langage. Groupe_Nominal → Article Adjectif Nom.

Grammaires : définition formelle

Définition: (Grammaire)

Une grammaire est un quadruplet $G = \langle V_T, V_N, S, R \rangle$, où :

- *V_T est un vocabulaire, appelé vocabulaire terminal;*
- *V_N est un vocabulaire, appelé vocabulaire non terminal, et tel que $V_N \cap V_T = \emptyset$. On pose $V = V_T \cup V_N$.*
- *$S \in V_N$ est appelé l'axiome de la grammaire.*
- *R est un ensemble de règles de la forme $u \rightarrow v$ avec :*
 - *$u \in V^+$*
 - *$v \in V^*$*

Exemples

Donner une grammaire pour les langages suivants :

- G_1 pour $(ab)^*(ba)^+$
- G_2 pour $a^n b^n$ avec $n \geq 0$
- G_3 pour $a^n b^n c^n$ avec $n \geq 1$

Donner V_T , V_N , l'axiome et les règles.

✓ Conventions :

- on fixe V_T . V_N est l'ensemble des symboles apparaissant dans les règles et n'appartenant pas à V_T , l'axiome est le symbole en partie gauche de la première règle.
- Si plusieurs règles $A \rightarrow w_1, \dots, A \rightarrow w_n$ on peut noter $A \rightarrow w_1 \mid \dots \mid w_n$.

Exemple 1

Donner une grammaire pour les langages suivants :

- G_1 pour $(ab)^*(ba)^+$

Donner V_T , V_N , l'axiome et les règles.

$$\begin{aligned} S &\rightarrow AB \\ A &\rightarrow abA \\ A &\rightarrow \epsilon \\ B &\rightarrow baB \\ B &\rightarrow ba \end{aligned}$$

$V_T = \{a, b\}$, $V_N = \{S, A, B\}$, S est l'axiome.
ou bien :

$$\begin{aligned} S &\rightarrow AB \\ A &\rightarrow abA \mid \epsilon \\ B &\rightarrow baB \mid ba \end{aligned}$$

Exemple 2

Donner une grammaire pour les langages suivants :

- G_2 pour $a^n b^n$ avec $n \geq 0$

Donner V_T , V_N , l'axiome et les règles.

$$S \rightarrow aSb$$

$$S \rightarrow \epsilon$$

$V_T = \{a, b\}$, $V_N = \{S\}$, S est l'axiome.

ou bien :

$$S \rightarrow aSb \mid \epsilon$$

Exemple 3

Donner une grammaire pour les langages suivants :

- G_3 pour $a^n b^n c^n$ avec $n \geq 1$

Donner V_T , V_N , l'axiome et les règles.

- (1) $S \rightarrow abc$
- (2) $S \rightarrow aSBc$
- (3) $cB \rightarrow Bc$
- (4) $bB \rightarrow bb$

$V_T = \{a, b, c\}$, $V_N = \{S, B\}$, S est l'axiome.

Summary

- 1 Introduction
- 2 Grammaires
- 3 Langage associé à une grammaire**
- 4 Hiérarchie de Chomsky

Relation de dérivation

Définition: (Relation de dérivation)

- Soit $G = \langle V_T, V_N, S, R \rangle$ une grammaire.
- Soit $x, y \in V^*$. On dit que x dérive vers y , noté $x \Longrightarrow y$ si et seulement si il existe une règle $u \rightarrow v$ et deux chaînes $\alpha, \beta \in V^*$ telles que $x = \alpha u \beta$ et $y = \alpha v \beta$.

Si on veut être précis on note \Longrightarrow_r , avec r une règle ou $\Longrightarrow_{p,r}$ avec p une position dans x et r une règle.

- ✓ Ne pas mélanger \rightarrow (pour les règles) et \Longrightarrow (pour les dérivations).
- ✓ Ne pas mélanger \Rightarrow (implication logique) et \Longrightarrow (pour les dérivations).

Dérivation de longueur quelconque

On note \Longrightarrow^p une dérivation de longueur p . Définie par :

$$\begin{array}{l}
 u \Longrightarrow^0 v \quad \Leftrightarrow \quad u = v \\
 u \Longrightarrow^1 v \quad \Leftrightarrow \quad u \Longrightarrow v \\
 u \Longrightarrow^{p+1} w \quad \Leftrightarrow \quad \exists v . u \Longrightarrow v \wedge v \Longrightarrow^p w
 \end{array}$$

✓ Propriété de composition des dérivations :

$$u_1 \Longrightarrow^{p_1} v_1 \quad u_2 \Longrightarrow^{p_2} v_2$$

$$u_1 u_2 \Longrightarrow^{p_1+p_2} v_1 v_2$$

On note \Longrightarrow^* la fermeture réflexive et transitive de \Longrightarrow .

$$\Longrightarrow^* = \bigcup_{i \in \mathbb{N}} \Longrightarrow^i$$

Exemple 1

$$V_T = \{a, b\}$$

$$V_N = \{S\}$$

$$R = \left\{ \begin{array}{l} S \rightarrow \varepsilon \\ S \rightarrow aSb \end{array} \right. \quad \text{noté également } S \rightarrow \varepsilon \mid aSb$$

- $S \Longrightarrow^1 \varepsilon$
- $S \Longrightarrow^1 aSb \Longrightarrow^1 ab \quad (S \Longrightarrow^2 ab)$
- $S \Longrightarrow aSb \Longrightarrow aaSbb \Longrightarrow aaaSbbb \Longrightarrow aaabbb \quad (S \Longrightarrow^* aaaabbbb)$

Exemple 2

- (1) $S \rightarrow abc$
- (2) $S \rightarrow aSBc$
- (3) $cB \rightarrow Bc$
- (4) $bB \rightarrow bb$

$$\begin{aligned} S &\Longrightarrow_2 aSBc \\ &\Longrightarrow_1 aabcBc \\ &\Longrightarrow_3 aabBcc \\ &\Longrightarrow_4 aabbcc \end{aligned}$$

Langage engendré

Définition: (Langage engendré par une grammaire)

- Soit une grammaire $G = \langle V_T, V_N, S, R \rangle$. Le langage engendré par G est $L(G) = L(S) = \{x \in V_T^* \mid S \Longrightarrow^* x\}$

Généralisation. Soit $w \in V^*$. On pose :

$$L(w) = \{x \in V_T^* \mid w \Longrightarrow^* x\}$$

Langage engendré - Exemples

Exemple. Soit $V_T = \{a, b\}$ et les règles suivantes :

$$\begin{aligned} S &\rightarrow AB & A &\rightarrow a & A &\rightarrow aA \\ B &\rightarrow \epsilon & B &\rightarrow bB \end{aligned}$$

$L(A)$? $L(B)$? $L(S)$? $L(ABa)$?

✓ **Propriété** : Deux grammaires G_1 et G_2 sont dites équivalentes ssi elles engendrent le même langage :

$$L(G_1) = L(G_2)$$

Grammaire : un processus énumératif

⇒ On peut voir les grammaires comme un processus permettant d'énumérer les mots du langage :

- 1 On part de l'axiome
- 2 On applique toutes les règles possibles sur toutes les occurrences possibles
- 3 on réitère le pas 2 sur les mots de dérivation obtenus

⇒ une procédure de semi-décision pour le problème $w \in L(G)$.

Exemple grammaire précédente:

pas 0 : S
pas 1 : AB
pas 2 : aB, aAB, A, AbB
pas 3 : a, abB, aaB, aaAb, aA, aAbB, a, aA, abB, aaAB
pas 4 : ...

$aa \in L(G)$? $ba \in L(G)$? Comment décider de l'arrêt ?

Summary

- 1 Introduction
- 2 Grammaires
- 3 Langage associé à une grammaire
- 4 Hiérarchie de Chomsky**

Hiérarchie de Chomsky

Noam Chomsky (1928) : linguiste et philosophe. 1950 : théorie des grammaires génératives.

- Une classification des grammaires (et des langages) qui permettra l'étude du compromis expressivité/décision.
- Une restriction sur la forme des règles
- 4 classes de grammaires :
 - Grammaires régulières (classe 3)
 - Grammaires hors-contexte (classe 2)
 - Grammaires sous-contexte (classe 1)
 - Grammaires générales (classe 0)

Grammaire régulière

Soit $G = \langle V_T, V_N, S, R \rangle$ une grammaire. G est dite **régulière** si et seulement si les règles sont d'une des formes suivantes :

- $A \rightarrow \epsilon$
- $A \rightarrow aB$

avec $A \in V_N$, $B \in V_N$ et $a \in V_T$.

✓ Exemples

Une telle grammaire est dite linéaire à droite. Il existe d'autres façons équivalentes (i.e. engendrant les mêmes langages) de décrire les grammaires régulières (voir TD).

C'est bien la même classe que celle qu'on a déjà vue ! (séance 2 ou 3)

Grammaire hors-contexte

Soit $G = \langle V_T, V_N, S, R \rangle$ une grammaire. G est dite **hors-contexte** si et seulement si les règles sont de la forme :

- $A \rightarrow w$

avec $A \in V_N$ et $w \in (V_T \cup V_N)^*$.

✓ Exemples

⇒ Une classe qu'on aime bien ! Bon compromis
Expressivité/décidabilité

Grammaire sous-contexte

Soit $G = \langle V_T, V_N, S, R \rangle$ une grammaire. G est dite **sous-contexte** si et seulement si les règles sont de la forme :

- $u \rightarrow v$ avec $|u| \leq |v|$

avec $u \in V^+$, $v \in V^+$. Rappel : par définition des grammaires $u \neq \epsilon$.

✓ Exemples

⇒ La condition sur la taille donnera un algorithme de décision pour $w \in L(G)$.

⇒ On énumère tous les mots $\alpha \in (V_T \cup V_N)^*$ tel que $S \Longrightarrow^* \alpha$ et $|\alpha| \leq |w|$. Si on n'a pas trouvé w on ne le trouvera pas.

Grammaire sous-contexte (suite)

- Une définition équivalente (si, si !). Règles de la forme :
 - $uAv \rightarrow uwv$avec $A \in V_N$ et u, v, w dans V^* et $w \neq \epsilon$.

Pour les 2 définitions :

Si ϵ dans le langage on peut ajouter les règles :

- $Z \rightarrow \epsilon$
- et $Z \rightarrow S$,

avec Z un nouveau symbole qui devient l'axiome.

Grammaire générale

Pas de restriction.

✓ Résultats :

- G régulière $\Rightarrow G$ hors-contexte
- G hors-contexte sans ϵ -règle $\Rightarrow G$ sous-contexte
- G sous-contexte $\Rightarrow G$ générale

On appelle ϵ -règle une règle de la forme $A \rightarrow \epsilon$.

✓ Questions :

- Soit G une grammaire. Peut-on décider de sa classe ?
- Grammaire des grammaires ?

Classes de langages

⇒ Extension de la notion de classes de grammaires aux langages.

Un langage L est dit régulier (hors-contexte, sous-contexte, général) si et seulement si il existe une grammaire G régulière (hors-contexte, sous-contexte, générale) telle que $L(G) = L$.

✓ Remarques :

- On s'intéresse généralement à la plus petite sous-classe d'un langage
- Prouver $L(G) = L$ est " complexe ". On verra une manière systématique de faire cette preuve (pour les langages hors-contexte).
- Il n'y a pas d'algorithme pour décider de la classe d'un langage.

Hiérarchie de langages

✓ Résultats :

- Extension des implications sur les grammaires aux langages
- Plus généralement L hors-contexte $\Rightarrow L$ sous-contexte (preuve en séance 2 ou 3)
- Inclusion stricte des classes de langages
- Les grammaires ne captent pas tous les langages

✓ Voir schéma au tableau

L Hors-contexte non régulier:

L Sous-contexte non Hors-contexte :

L général non Sous-contexte :

L non général:

Ce qu'on étudiera

- Les propriétés (en termes de décidabilité) de ces différentes sous-classes
 - $w \in L(G)$?
 - $L(G_1) = L(G_2)$?
 - ...
- Plus particulièrement la classe des langages hors-contexte et ses propriétés