

Langages formels : grammaires

Stéphane Le Roux leroux@lsv.fr

ENS Paris-Saclay

2023-2024

Hiérarchie de Chomsky

4 types de grammaires de plus en plus restrictifs.

- Type 0, dit des grammaires générales : correspond aux machines de Turing.
- Type 1, grammaires contextuelles : $NSPACE(n)$.
- Type 2, grammaires hors-contexte (ou algébriques) : automates à pile.
- Type 3, grammaires rationnelles : automates finis.

Type 0, grammaires générales

Définition : grammaire de type 0

$G = (\Sigma, V, \rightarrow, S)$ où

- Σ est l'alphabet terminal (généralement lettres minuscules)
- V est l'alphabet non terminal, dit des variables (généralement lettres majuscules). $V \cap \Sigma = \emptyset$.
- S est la variable initiale.
- $\rightarrow \subseteq (\Sigma \cup V)^* \times (\Sigma \cup V)^*$ est un ensemble fini de règles de production.

Définition : dérivation terminale et langage engendré

- Soient $u, v, v', w \in (\Sigma \cup V)^*$ tels que $v \rightarrow v'$. On note alors aussi $uvw \rightarrow uv'w$. Clôture de \rightarrow par passage au contexte.
- Le langage engendré par G est $L_G := \{u \in \Sigma^* \mid S \rightarrow^+ u\}$. (\rightarrow^+ est la clôture transitive de \rightarrow .)
- Un langage engendré par une grammaire de type 0 est dit de type 0.

Exemple

$$\begin{array}{llll} 1: & S \rightarrow DXaF & 3: & XF \rightarrow YF & 5: & DY \rightarrow DX & 7: & aZ \rightarrow Za \\ 2: & Xa \rightarrow aaX & 4: & aY \rightarrow Ya & 6: & XF \rightarrow Z & 8: & DZ \rightarrow \epsilon \end{array}$$

- ① $Xa^n \rightarrow^* a^{2n}X$ (règle 2 et récurrence sur $n > 0$)
- ② $a^nY \rightarrow^* Ya^n$ (règle 4 et récurrence sur $n > 0$)
- ③ $DXa^nF \rightarrow^* DXa^{2n}F$ (règle 3, lemmes ci-dessus, et règle 5)
- ④ $S \rightarrow DXa^{2^n}F$ pour tout $n \in \mathbb{N}$. (règle 1 et récurrence sur n par le lemme ci-dessus)
- ⑤ $a^nZ \rightarrow^* Za^n$ (règle 7 et récurrence sur n)
- ⑥ $DXa^nF \rightarrow^* a^{2^n}$ (règle 6, deux lemmes ci-dessus, et règle 8)
- ⑦ $S \rightarrow^* a^{2^n}$ pour tout $n > 0$ (deux lemmes ci-dessus)
- ⑧ Montrons (semi-formellement) que toute dérivation est de ce type :
 - ▶ La règle 8 est la seule qui ne produit pas de symboles non terminaux.
 - ▶ Le Z est produit par la règle 6, et la grammaire devient déterministe.
 - ▶ D et F sont en bout de mot, sauf quand ils sont effacés.
 - ▶ Une décision est prise seulement pour Da^nXF , et n est puissance de 2 (par récurrence).

Caractérisation du type 0

Théorème (Chomsky, 1959)

Un langage (alphabet fini) est de type 0 ssi il est récursivement énumérable.

Par double implication. Soit $G = (\Sigma, V, \rightarrow, S)$ une grammaire. Mq $L_G := \{u \in \Sigma^* \mid S \rightarrow^+ u\}$ est r.e. en définissant une MT non-déterministe à deux bandes qui l'accepte. La bande de travail est initialisé à S . Puis on simule une dérivation de G sur cette bande.

- 1 On sélectionne une règle de production de manière non-déterministe
- 2 On sélectionne un endroit dans le contenu de la bande de travail.
- 3 Si la zone du contenu égale la partie gauche de la règle, on met le contenu à jour.
- 4 Si le contenu égale l'entrée, on accepte. Sinon, on répète.

Les mots acceptés sont donc exactement les mots dérivables.

Caractérisation du type 0 (II)

Réciproquement, soit $L \subseteq \Sigma^*$ accepté par une MTD $(Q, q_0, \Sigma, \delta, B, \$)$. On définit une grammaire d'alphabet terminal Σ . La grammaire "devine" un mot, simule l'effet de la MTD sur ce mot, puis si la MTD accepte, termine avec le mot initial. Pour cela, il faut en garder une copie.

- On devine un mot :

$$1 : S \rightarrow q_0 D \quad 2 : D \rightarrow (a, a) D \quad \forall a \in \Sigma \quad 3 : D \rightarrow E$$

- On devine un espace suffisant sur la bande pour simuler la MTD.

$$4 : E \rightarrow (B, B) E \quad 5 : E \rightarrow \epsilon.$$

- On simule le calcul de la MTD sur la deuxième composante des couples.

- ▶ Pour tout $\delta(q, X) = (q', Y, droite)$ et $a \in \Sigma$, on pose $q(a, X) \rightarrow (a, Y)q'$.

- ▶ Pour tout $\delta(q, X) = (q', Y, gauche)$ et $a, b \in \Sigma$ et Z , on pose $(b, Z)q(a, X) \rightarrow q'(b, Z)(a, Y)$.

- Si la MTD accepte, on projette sur la première composante. Pour tout $q \in F$ et $a \in \Sigma$, on pose

$$(a, X)q \rightarrow qa q \quad q(a, X) \rightarrow qa q \quad q \rightarrow \epsilon$$

Type 1, grammaires contextuelles

Définition : grammaire de type 1

Une grammaire $(\Sigma, V, \rightarrow, S)$ est dite contextuelle si toute règle $u \rightarrow v$ vérifie $|u| \leq |v|$, dite règle croissante. Un langage engendré par une grammaire de type 1 est dit de type 1 ou contextuel.

Remarque

Un langage de type 1 ne contient pas le mot vide. Certains auteurs exigent la croissance seulement pour les règles dont le membre gauche n'est pas S (et S n'apparaît jamais à droite).

Rappel de la grammaire de type 0 produisant $\{a^{2^n} \mid n > 0\}$.

$$\begin{array}{llll} 1: & S \rightarrow DXaF & 3: & XF \rightarrow YF & 5: & DY \rightarrow DX & 7: & aZ \rightarrow Za \\ 2: & Xa \rightarrow aaX & 4: & aY \rightarrow Ya & 6: & XF \rightarrow Z & 8: & DZ \rightarrow \epsilon \end{array}$$

Les règles 6 et 8 ne sont pas croissantes.

Exemple

Proposition

Le langage $\{a^{2^n} \mid n > 0\}$ est contextuel.

$$\begin{array}{llll} 1 & S \rightarrow aa & 3 & T \rightarrow aa & 5 & Xaa \rightarrow aaXa & 7 & XaaF \rightarrow aaaa \\ 2 & S \rightarrow XTF & 4 & T \rightarrow XT & 6 & XaF \rightarrow aaF \end{array}$$

- 1 Le mot aa est produit par la règle 1.
- 2 Un mot $X^{n+1}aaF$ est produit par 2,4,3.
- 3 $Xa^{n+1}F \rightarrow^+ a^{2(n+1)}F$ (récurrence sur $n \in \mathbb{N}$, règles 5 et 6)
- 4 $Xa^{n+2}F \rightarrow^+ a^{2(n+2)}$ (récurrence sur $n \in \mathbb{N}$, règles 5 et 7)
- 5 $X^k a^{n+1}F \rightarrow^* a^{2^k(n+1)}F$ (récurrence sur $k \in \mathbb{N}$, ne pas fixer n , lemmes ci-dessus)
- 6 $X^k a^{n+2}F \rightarrow^* a^{2^k(n+2)}$ (récurrence sur $k \in \mathbb{N}$, lemmes ci-dessus)
- 7 $S \rightarrow^+ a^{2^{k+1}}$ (règle 2,4,3, puis lemme ci-dessus avec $n = 0$)

Grammaires en forme normale contextuelle

Définition : forme normale

Une grammaire $(\Sigma, V, \rightarrow, S)$ est en forme normale contextuelle si ses règles sont de la forme $uXw \rightarrow uvw$ avec $X \in V$ et $v \neq \epsilon$.

Remarques

- Une grammaire en forme normale contextuelle est donc contextuelle
- Les règles 5 et 7 de la grammaire ci-dessous ne sont pas en forme normale contextuelle.

$$\begin{array}{llll} 1 & S \rightarrow aa & 3 & T \rightarrow aa & 5 & Xaa \rightarrow aaXa & 7 & XaaF \rightarrow aaaa \\ 2 & S \rightarrow XTF & 4 & T \rightarrow XT & 6 & XaF \rightarrow aaF \end{array}$$

Théorème

Tout langage sans le mot vide est contextuel ssi il est engendré par une grammaire en forme normale contextuelle

⇐ par une remarque ci-dessus.

Type 1 et formes normales

Théorème

Tout langage sans le mot vide est contextuel ssi il est engendré par une grammaire en forme normale contextuelle.

Soit $(\Sigma, V, \rightarrow, S)$ une grammaire contextuelle/croissante n'engendrant pas le mot vide. On définit une grammaire $(\Sigma, V \uplus X_\Sigma, \rightsquigarrow, S)$ en forme normale qui engendre le même langage, où $X_\Sigma := \{X_a \mid a \in \Sigma\}$.

- 1 Pour tout $a \in \Sigma$, on pose $X_a \rightsquigarrow a$.
- 2 Pour tout $u \rightarrow v$, on pose $f(u) \rightarrow_0 f(v)$, où dans $f(u)$, chaque $a \in \Sigma$ de u a été remplacé par X_a .
- 3 Pour tout $A_1 \dots A_n \rightarrow_0 B_1 \dots B_{n+k}$, on pose $A_1 \dots A_n \rightsquigarrow B_1 A_2 \dots A_n \rightsquigarrow B_1 B_2 A_3 \dots A_n \rightsquigarrow \dots \rightsquigarrow B_1 \dots B_{n-1} A_n \rightsquigarrow B_1 \dots B_{n+k}$

Caractérisation du type 1

Théorème

Un langage sans le mot vide est de type 1 ssi il est dans $NSPACE(n)$.

Par double implication. Soit $G = (\Sigma, V, \rightarrow, S)$ une grammaire croissante. On modifie la MT non-déterministe de la caractérisation "type 0 ssi r.e." en se restreignant à un espace de travail de même longueur que l'entrée. Cette restriction ne change pas le langage accepté, car la grammaire est croissante. Réciproquement, soit $L \subseteq \Sigma^*$ accepté par une MT non-déterministe $(Q, q_0, \Sigma, \delta, B, \$)$ en espace identique à l'entrée. On rappelle d'abord la grammaire de "type 0 ssi r.e." :

- 1 $S \rightarrow q_0 D \quad D \rightarrow (a, a) D \quad \forall a \in \Sigma \quad D \rightarrow E$
- 2 $E \rightarrow (B, B) E \quad E \rightarrow \epsilon.$
- 3 $q(a, X) \rightarrow (a, Y) q'$ pour tout $\delta(q, X) = (q', Y, droite)$ et $a \in \Sigma$.
- 4 $(b, Z) q(a, X) \rightarrow q'(b, Z)(a, Y)$ pour tout $\delta(q, X) = (q', Y, gauche)$ et $a \in \Sigma$.
- 5 $(a, X) q \rightarrow q a q \quad q(a, X) \rightarrow q a q \quad q \rightarrow \epsilon$ pour tout $q \in F$ et $a \in \Sigma$.

Caractérisation du type 1 (II)

- 1 $S \rightarrow q_0 D \quad D \rightarrow (a, a) D \quad \forall a \in \Sigma \quad D \rightarrow E$
- 2 $E \rightarrow (B, B) E \quad E \rightarrow \epsilon.$
- 3 $q(a, X) \rightarrow (a, Y) q'$ pour tout $\delta(q, X) = (q', Y, droite)$ et $a \in \Sigma.$
- 4 $(b, Z) q(a, X) \rightarrow q'(b, Z)(a, Y)$ pour tout $\delta(q, X) = (q', Y, gauche).$
- 5 $(a, X) q \rightarrow q a q \quad q(a, X) \rightarrow q a q \quad q \rightarrow \epsilon$ pour tout $q \in F.$

On suppose pour simplifier que la MT n'utilise que la bande d'entrée.

Grammaire modifiée (de symboles terminaux Σ) :

- 1 $S \rightarrow (a, q_0 a) D \quad S \rightarrow (a, q_0 a F) \quad D \rightarrow (a, a) D \quad D \rightarrow (a, a F)$
- 2 Pour tout $\delta(q, X) = (q', Y, droite)$ et $a \in \Sigma$, on pose $(a, qX)(b, Z) \rightarrow (a, Y)(b, q'Z).$
- 3 Pour tout $\delta(q, X) = (q', Y, gauche)$ et $a \in \Sigma$, on pose $(b, Z)(a, qX) \rightarrow (b, q'Z)(a, Y)$ et $(b, Z)(a, qXF) \rightarrow (b, q'Z)(a, YF)$
- 4 Pour tout $q \in F$ et $a, b \in \Sigma$ et X, Y , on pose $(a, qX) \rightarrow a$ et $(a, qX)(b, Y) \rightarrow (a, qX)(b, qY)$ et $(b, Y)(a, qX) \rightarrow (b, qY)(a, qX)$

Type 1 et décidabilité

Théorème

Le problème suivant est indécidable :

- Entrée : une grammaire de type 1.
- Sortie : le langage engendré est-il vide ?

Théorème (Kuroda 1964 pour les grammaires déterministe)

Le problème suivant est PSPACE-complet :

- Entrée : une grammaire de type 1 et un mot.
- Sortie : ce mot est-il engendré par la grammaire ?

Type 2, grammaires hors contexte

Définition

Une grammaire $(\Sigma, V, \rightarrow, S)$ est dite de type 2 ou hors contexte ou algébrique si $u \rightarrow v$ implique $u \in V$, i.e. chaque membre gauche est une variable, i.e. $\rightarrow \subseteq V \times (V \cup \Sigma)^*$.

Un langage est de type 2 ou hors contexte ou algébrique s'il est engendré par une grammaire de type 2.

Exemples

- Le langage $\{a^n b^n \mid n \in \mathbb{N}\}$ est algébrique. $S \rightarrow \epsilon$ et $S \rightarrow aSb$
- La langage des expressions bien parenthésées est algébrique. Cf TD.

Les grammaires de type 2 sont presque toutes de type 1, mais certaines de leurs règles ne sont pas croissantes.

Grammaires hors contexte, lemme fondamental

Lemme

Soit une grammaire algébrique $(\Sigma, V, \rightarrow, S)$ et u, v, w et $n \in \mathbb{N}$ tels que $uv \rightarrow^n w$. Alors il existe $w_1, w_2 \in \Sigma^*$ et $n_1, n_2 \in \mathbb{N}$ tels que $w = w_1 w_2$ et $n = n_1 + n_2$ et $u \rightarrow^{n_1} w_1$ et $v \rightarrow^{n_2} w_2$.

Preuve

Par récurrence sur n .

- Pour $n = 0$, les (seuls) témoins sont $w_1 := u$ et $w_2 := v$ et $n_1 = n_2 = 0$.
- Cas inductif : Supposons $uv \rightarrow^{n+1} w$. Soit y tel que $uv \rightarrow y$ et $y \rightarrow^n w$. 1er cas, $u = u_1 X u_2$ et $y = u_1 u_X u_2 v$ avec $X \rightarrow u_X$. Par HR, soient w_1, w_2, n_1, n_2 tels que $w = w_1 w_2$ et $u_1 u_X u_2 \rightarrow^{n_1} w_1$ et $v \rightarrow^{n_2} w_2$. On a $u \rightarrow u_1 u_X u_2 \rightarrow^{n_1} w_1$ donc $u \rightarrow^{n_1+1} w_1$, donc $w_1, w_2, n_1 + 1, n_2$ sont des témoins. Le 2ème cas est similaire.

Type 3, grammaires linéaires

Définition

Une grammaire $(\Sigma, V, \rightarrow, S)$ est linéaire si elle est hors contexte et que dans chaque membre droit des règles apparaît au plus une variable, i.e.

$$\rightarrow \subseteq V \times (\Sigma^* \cup \Sigma^* V \Sigma^*)$$

- Elle est linéaire gauche si $\rightarrow \subseteq V \times (\Sigma^* \cup V \Sigma^*)$
- Elle est linéaire droite si $\rightarrow \subseteq V \times (\Sigma^* \cup \Sigma^* V)$

Exemples

- Le langage $\{a^n b^n \mid n \in \mathbb{N}\}$ est linéaire. $S \rightarrow \epsilon$ et $S \rightarrow aSb$
- Le langage $\{a^n b^n c^p \mid n, p \in \mathbb{N}\}$ est linéaire.
 $S \rightarrow Sc \mid T$ (raccourci de $S \rightarrow Sc \quad S \rightarrow T$) et $T \rightarrow \epsilon \mid aTb$

- Les grammaires de type 3 sont de type 2.
- Les grammaires de type 3 sont presque toutes de type 1, mais certaines de leurs règles ne sont pas croissantes.

Grammaires linéaires droites

Rappel : une grammaire $(\Sigma, V, \rightarrow, S)$ est linéaire droite si $\rightarrow \subseteq V \times (\Sigma^* \cup \Sigma^* V)$.

Définition

Une grammaire $(\Sigma, V, \rightarrow, S)$ est linéaire droite stricte si $\rightarrow \subseteq V \times (\{\epsilon\} \cup \Sigma \cup \Sigma V)$.

Lemme

Pour toute grammaire linéaire droite, il existe une grammaire linéaire droite stricte produisant le même langage.

Preuve

- Si $A \rightarrow \epsilon$, on pose $A \rightarrow' \epsilon$
- Soit $R := (A, uB) \in \rightarrow$, et soit $n_R := |u|$. On pose $A \rightarrow' u_1 X_1^R$ et $X_1^R \rightarrow' u_2 X_2^R \dots X_{n_R-2}^R \rightarrow' u_{n_R-1} X_{n_R-1}^R$ et $X_{n_R-1}^R \rightarrow' u_{n_R} B$.
- Soit $R := (A, u) \in \rightarrow$. Similaire à ci-dessus, en remplaçant $X_{n_R-1}^R \rightarrow' u_{n_R} B$ par $X_{n_R-1}^R \rightarrow' u_{n_R}$.

Linéaire droit vers rationnel

Lemme

Si un langage est linéaire droit (ou gauche), alors il est rationnel.

Preuve

Soit $L \subseteq \Sigma^*$ un langage linéaire droit. Par un lemme précédent, soit $(\Sigma, V, \rightarrow, S)$ une grammaire linéaire droite stricte le produisant. Soit $\mathcal{A} = (\Sigma, Q, \Delta, I, F)$ l'AFN tel que :

- $Q := V \sqcup \{q_f\}$
- $I := \{S\}$
- Si $S \rightarrow \epsilon$ est dans G , alors $F := \{q_f\} \sqcup \{S\}$, sinon $F := \{q_f\}$.
- $(A, a, B) \in \Delta$ si $A \rightarrow aB$ est dans G .
- $(A, a, q_f) \in \Delta$ si $A \rightarrow a$ est dans G .

On a $A \rightarrow aB$ ssi $A \xrightarrow{a}_{\mathcal{A}} B$. Donc $A \rightarrow^* uB$ ssi $A \xrightarrow{u}_{\mathcal{A}} B$, par récurrence sur u . Donc, pour $u \neq \epsilon$ on a $S \rightarrow^* u$ ssi $S \xrightarrow{u}_{\mathcal{A}} q_f$. Et $S \rightarrow^* \epsilon$ ssi $S \in F$. Ainsi u est produit par G ssi u est accepté par \mathcal{A} .

Rationnel vers linéaire droit

Lemme

Si un langage est rationnel, il est linéaire droit (ou gauche)

Soit $L \subseteq \Sigma^*$ reconnu par un automate déterministe $(\Sigma, Q, \delta, i, F)$ (avec $\Sigma \cap Q = \emptyset$). On suppose d'abord que $i \notin F$. On définit une grammaire $G = (\Sigma, Q, \rightarrow, i)$:

- Pour tout $q \in Q$ et $a \in \Sigma$, on pose $q \rightarrow a\delta(q, a)$.
- Pour tout $q \in Q$ et $a \in \Sigma$ tel que $\delta(q, a) \in F$, on pose $q \rightarrow a$.

On montre que $i \rightarrow^* u\delta(i, u)$ pour tout $u \in \Sigma^*$, par récurrence sur u .

Ainsi, si $\delta(i, u) \in F$ on a aussi $i \rightarrow^* u$. En effet, si $\delta(i, u) \in F$ alors $u \neq \epsilon$ par l'hypothèse $i \notin F$, donc il suffit de remplacer la dernière règle utilisée dans $i \rightarrow^* ua\delta(i, ua)$ par $\delta(i, u) \rightarrow a$. Réciproquement, si $q \rightarrow^* u$, alors la dernière règle utilisée est $\delta(i, u) \rightarrow a$ donc $\delta(i, u) \in F$, i.e. $u \in L$.

Si $i \in F$, on modifie un automate reconnaissant L en un automate reconnaissant $L \setminus \{\epsilon\}$ et on obtient une grammaire linéaire droite

$G = (\Sigma, Q, \rightarrow, i)$ produisant $L \setminus \{\epsilon\}$. On définit enfin une grammaire $G' = (\Sigma, Q, \rightarrow, S)$ en ajoutant $S \rightarrow \epsilon$ et $S \rightarrow i$ aux règles de G .

Caractérisation des langages linéaires droits/gauches

Théorème

Un langage est rationnel ssi il est linéaire droit (ou gauche)

Preuve

Par les deux lemmes précédents.