

Feuille d'exercices n°13 - Grammaires non contextuelles - partie 1

Notions abordées

- exemple de grammaires non contextuelles
- suite de dérivations, arbre de dérivation
- langage d'une grammaire non contextuelle, preuve par induction
- exemple de langages non contextuels : langage de Dyck, mots de Łukasiewicz

Exercice 1 : Exemples de dérivations

Soit $\Sigma = \{a, b\}$, $\mathcal{V} = \{S, D, T, X\}$, et \mathcal{G} la grammaire non contextuelle de symbole initial S , et contenant les règles de production ci-contre^a.

$$\begin{array}{l} S \rightarrow XSX \mid D \\ D \rightarrow aTb \mid bTa \\ T \rightarrow XTX \mid X \mid \varepsilon \\ X \rightarrow a \mid b \end{array}$$

Q. 1 Parmi les dérivations suivantes, lesquelles sont vraies ?

$$(a) T \Rightarrow aba \qquad (b) T \xrightarrow{*} aba \qquad (c) T \Rightarrow T \qquad (d) T \xrightarrow{*} T$$

Q. 2 Parmi les dérivations suivantes, lesquelles sont vraies ?

$$\begin{array}{lll} (a) XXX \xrightarrow{*} aba & (c) T \xrightarrow{*} XX & (e) D \xrightarrow{*} \varepsilon \\ (b) X \xrightarrow{*} aba & (d) T \xrightarrow{*} XXX & \end{array}$$

Q. 3 Donner 3 mots de $\mathcal{L}(\mathcal{G})$. Justifier leur appartenance à $\mathcal{L}(\mathcal{G})$ par une dérivation.

Q. 4 Donner 3 mots de Σ^* qui ne sont pas dans $\mathcal{L}(\mathcal{G})$.

Q. 5 Donner une description en français de $\mathcal{L}(\mathcal{G})$. En première lecture de cet énoncé, on ne demande pas de preuve du résultat avancé.

Exercice 2 : Arbres de dérivations

Soit $\Sigma = \{a, b, c, \dots, z, +, (,)\}$, $\mathcal{V} = \{E, S, P, F, T\}$, et la grammaire \mathcal{G} de symbole initial E et de règles de production ci-contre.

$$\begin{array}{l} S \rightarrow S + P \mid P \\ P \rightarrow PF \mid F \\ F \rightarrow (S) \mid T \\ T \rightarrow a \mid b \mid c \mid \dots \mid z \end{array}$$

Q. 1 Donner un arbre de dérivation de $ab + bc$.

Q. 2 Donner un arbre de dérivation de $b + (a + b)c + a(bc)$.

Q. 3 Que représente cette grammaire, *i.e.* que représentent les mots engendrés par \mathcal{G} ?

^a. Lorsque plusieurs règles de production ont le même membre gauche, on peut les représenter factorisées en séparant les différents membres droits par $|$. Par exemple, on note $A \rightarrow w|w'$ pour les deux règles $A \rightarrow w$ et $A \rightarrow w'$.

Exercice 3 : Construction de grammaires

- Q. 1** Soit $\Sigma = \{a, b\}$. Donner une grammaire non contextuelle \mathcal{G}_i de langage L_i ci-dessous.
- $L_0 = \{w \in \Sigma^* \mid |w| \geq 3\}$;
 - $L_1 = \{w \in \Sigma^* \mid |w|_a \geq 3\}$;
 - $L_2 = \{w \in \Sigma^+ \mid w \text{ commence et finit par la même lettre}\}$;
 - $L_3 = \emptyset$;
- Q. 2** Soit $\Sigma = \{a, b\}$. Donner une grammaire non contextuelle \mathcal{G}_i de langage L_i ci-dessous ♣.
- $L_4 = \{w \in \Sigma^* \mid |w| \equiv 1[2]\}$;
 - $L_5 = \{w \in \Sigma^* \mid |w| \equiv 1[2] \text{ et sa lettre du milieu est } a\}$;
 - $L_6 = \{w \in \Sigma^* \mid w \text{ est un palindrome}\}$;
 - $L_7 = L_6^C$;
- Q. 3** Donner une grammaire non contextuelle \mathcal{G}_i de langage L_i ci-dessous.
- $L_8 = \{a^n b^n \mid n \in \mathbb{N}\}$;
 - $L_9 = \{a^n b^m \mid (n, m) \in \mathbb{N}^2, m \geq n\}$;
 - $L_{10} = \{a^n b^m \mid (n, m) \in \mathbb{N}^2, m \geq 2n\}$;
- Q. 4** Soit $\Sigma = \{a, b\}$. Donner une grammaire non contextuelle \mathcal{G}_i de langage L_i ci-dessous.
- $L_{11} = \{w \in \Sigma^* \mid |w|_a \geq |w|_b\}$;
 - $L_{12} = L_{11}^C$;
- Q. 5** Soit $\Sigma = \{a, b, \#\}$. Donner une grammaire non contextuelle \mathcal{G}_{13} de langage L_{13} ci-dessous.
- $L_{13} = \{w\#x \mid (w, x) \in (\{a, b\}^*)^2, \bar{w}^R \text{ est un sous-mot de } x \text{ où } \bar{w}^R \text{ désigne le miroir de } w\}$.

Exercice 4 : Langage de Dyck

Le langage des mots de Dyck est le langage des mots sur $\Sigma = \{(\,)\}$ bien parenthésés, c'est-à-dire le plus petit langage $L \subseteq \Sigma^*$ tel que :

- $\varepsilon \in L$;
- $\forall u \in L, (u) \in L$;
- $\forall (u, v) \in L \times L, u \cdot v \in L$.

- Q. 1** Donner une grammaire non contextuelle \mathcal{G} reconnaissant le langage de Dyck.
- Q. 2** Montrer que les mots u de $\mathcal{L}(\mathcal{G})$ sont tels que :
- $|u|_{(} = |u|_{)}$
 - pour tout préfixe v de u , $|v|_{(} \geq |v|_{)}$
- Q. 3** Montrer que les mots $u \in \Sigma^*$ vérifiant ces deux conditions sont bien parenthésés.
- Q. 4** En déduire une fonction OCAML testant si un mot est dans le langage de Dyck.
- Q. 5** Démontrer que ce langage n'est pas régulier.

♣. Lorsque la définition d'un langage fait intervenir le complémentaire, celui-ci s'entend par rapport à Σ^* .

Exercice 5 : Reasonner par induction sur une grammaire

Soit $\Sigma = \{a, b\}$, $\mathcal{V} = \{S\}$ et la grammaire \mathcal{G} contenant les règles de production :

$$S \rightarrow aS \mid Sb \mid a \mid b \mid \varepsilon$$

- Q. 1 Montrer que ba n'est sous-mot d'aucun mot de $\mathcal{L}(\mathcal{G})$.
- Q. 2 Donner $\mathcal{L}(\mathcal{G})$.
- Q. 3 Donner une grammaire reconnaissant $\mathcal{L}(\mathcal{G})$ et assurant que chaque mot est obtenu par une unique dérivation depuis le symbole initial.

Exercice 6 : Ambiguïté

Soit $\Sigma = \{a, b\}$, $\mathcal{V} = \{S\}$, et la grammaire \mathcal{G} de symbole initial S et de règles de production :

$$S \rightarrow aS \mid aSbS \mid \varepsilon$$

- Q. 1 Montrer que \mathcal{G} est ambiguë.
- Q. 2 Montrer que $\mathcal{L}(G) = \{v \in \Sigma^* \mid \text{pour tout } u \text{ préfixe de } v, |u|_a \geq |u|_b\}$.
- Q. 3 Donner une grammaire non ambiguë reconnaissant $\mathcal{L}(G)$.

Exercice 7 : Mots de Łukasiewicz [CENTRALE 2008]

On considère l'ensemble de deux symboles $\Sigma = \{\square, \circ\}$, Σ contient donc uniquement le symbole "carré" : \square et le symbole "rond" : \circ . On s'intéresse dans cet exercice à un sous-ensemble de Σ^* , nommé **mots de Łukasiewicz**. On rappelle qu'étant donné un mot $w = w_1w_2 \dots w_n \in \Sigma^*$, la notation $|w|$ désigne la longueur de w , n ici. On considère la fonction $va : \Sigma \rightarrow \{-1, 1\}$ telle que $va(\square) = -1$ et $va(\circ) = 1$. À un mot $w = w_1w_2 \dots w_n \in \Sigma^*$ et à un entier $i \in \llbracket 0, n \rrbracket$ on associe la valeur : $\bar{w}^i = \sum_{k=1}^i va(w_k)$, en prenant comme convention que $\sum_{k=1}^0 va(w_k) = 0$. Par exemple : $\bar{\circ\circ\square\square}^4 = va(\circ) + va(\circ) + va(\square) + va(\square) = 1 + 1 - 1 - 1 = 0$. et $\bar{\varepsilon}^0 = 0$.

On définit alors l'ensemble des **mots de Łukasiewicz** comme étant l'ensemble des mots $w \in \Sigma^*$ tels que

$$\forall i \in \llbracket 0, |w| - 1 \rrbracket, \bar{w}^i \geq 0$$

et $\bar{w}^{|w|} = -1$

Par exemple : $w = \circ\circ\square\square \in \mathcal{L}$, en effet les valeurs des \bar{w}^i sont :

i	0	1	2	3	4	5
\bar{w}^i	0	1	2	1	0	-1

- Q. 1 Donner l'ensemble des éléments de \mathcal{L} de longueur 1, 2, 3.
- Q. 2 Donner (en justifiant votre résultat) l'ensemble des éléments de \mathcal{L} de longueur paire.

On suppose définis en OCaml les types et fonctions ci-contre. Le type `sym` est utilisé pour représenter l'ensemble Σ : le symbole \circ est représenté par le constructeur `R` (pour "rond") et \square est représenté par le constructeur `C` (pour "carré"). Le type `word` est utilisé pour représenter les mots de Σ^* . La fonction `va` implémente la fonction `va` définie ci-dessus.

```

1 | type sym = | R | C
2 | type word = sym list
3 | let va (s: sym) : int =
4 |   match s with
5 |   | R -> 1
6 |   | C -> -1

```

- Q. 3** L'ensemble des mots de Łukasiewicz est-il régulier ?
- Q. 4** Définir une fonction `est_luka : word -> bool` permettant de tester si un mot est de Łukasiewicz, *i.e.* permettant de tester, pour $w \in \Sigma^*$, si $w \in \mathcal{L}$. On proposera une implémentation ayant une complexité pire cas en $\mathcal{O}(n)$.
- Q. 5** On appelle préfixe strict d'un mot $w \in \Sigma^*$, un mot $u \in \Sigma^*$ tel qu'il existe un mot $v \in \Sigma^* \setminus \{\varepsilon\}$ tel que $w = u \cdot v$. Montrer qu'un préfixe strict d'un mot de \mathcal{L} n'est pas un mot de \mathcal{L} .
- Q. 6** Montrer que si $u \in \mathcal{L}$ et $v \in \mathcal{L}$ alors $\circ \cdot u \cdot v \in \mathcal{L}$.
- Q. 7** Montrer que si $w \in \mathcal{L}$ et $|w| \neq 1$ alors il existe un unique couple $(u, v) \in \mathcal{L} \times \mathcal{L}$ tel que $w = \circ \cdot u \cdot v$.
- Q. 8** Montrer qu'il existe une grammaire contextuelle non ambiguë reconnaissant l'ensemble des mots de Łukasiewicz.
- Q. 9** Donner une fonction `decompose : word -> word * word` prenant en argument un mot de \mathcal{L} de taille différente de 1 (et de 0 car $\varepsilon \notin \mathcal{L}$) et calculant la décomposition de la Q. 7.

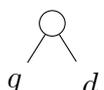
Exemples :

```
decompose [R; R; C; C; C] = ([R; C; C], [C])
decompose [R; R; C; C; R; C; C] = ([R; C; C], [R; C; C])
```

On définit maintenant l'ensemble des arbres binaires \mathbb{B} **sans étiquette** par les deux règles de construction :

```
1 | type btree =
2 |   | N of btree * btree          (* Nœud interne *)
3 |   | E                          (* Arbre vide *)
```

Autrement énoncé :

- $\square \in \mathbb{B}$
- Si $g \in \mathbb{B}$ et $d \in \mathbb{B}$ alors  $\in \mathbb{B}$

- Q. 10** Donner une bijection naturelle de \mathbb{B} dans \mathcal{L} , induite par la Q. 8
- Q. 11** Définir en OCAML deux fonctions `to_word : btree -> word` et `from_word : word -> btree` telles que : $\forall w \in \mathcal{L}, (\text{to_word } (\text{from_word } w)) = w$ et $\forall b \in \mathbb{B}, (\text{from_word } (\text{to_word } b)) = b$.

Exemples :

```
from_word [R; R; C; C; R; C; C] = N (N (E, E), N (E, E))
to_word (N (N (E, E), N (E, E))) = [R; R; C; C; R; C; C]
```

- Q. 12** Démontrer que $\forall w \in \mathcal{L}, |w| \geq 3 \Rightarrow \exists (u, v) \in \Sigma^*, w = u \cdot \circ \square \square \cdot v$.