

Td n° 14

Grammaires non contextuelles
(1)

1 Exemples de dérivations

1. Les dérivations (b), et (d) sont vraies.
2. Les dérivations (a), (c), et (d).
3. On a $\{ab, ba, aab\} \subseteq \mathcal{L}(\mathcal{G})$. En effet,
 - $S \Rightarrow D \Rightarrow aTb \Rightarrow ab$,
 - $S \Rightarrow D \Rightarrow bTa \Rightarrow ba$,
 - $S \Rightarrow D \Rightarrow aTb \Rightarrow aXb \Rightarrow aab$.
4. On a $\varepsilon \notin \mathcal{L}(\mathcal{G})$, $aa \notin \mathcal{L}(\mathcal{G})$ et $bb \notin \mathcal{L}(\mathcal{G})$.
5. Le langage $\mathcal{L}(\mathcal{G})$ est l'ensemble des mots non palindromes.

2 Arbres de dérivations

1.




FIGURE 1 – Arbre de dérivation de $ab+bc$ dans la grammaire \mathcal{G}

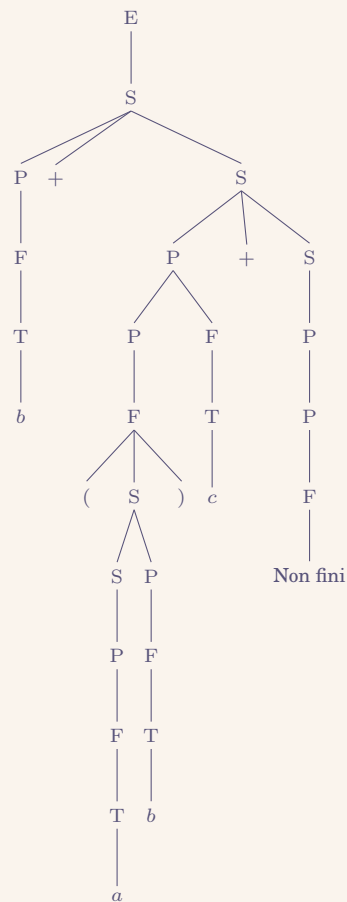


FIGURE 2

2.

3 Construction de grammaires

1. — $\mathcal{G}_0 = (\Sigma, \{L, A, S\}, \{S \rightarrow LLLA, L \rightarrow a \mid b, A \rightarrow LA \mid \varepsilon\}, S)$,
- $\mathcal{G}_1 = (\Sigma, \{L, A, S\}, \{S \rightarrow AaAaAaA, A \rightarrow LA \mid \varepsilon, L \rightarrow a \mid b\}, S)$,
- $\mathcal{G}_2 = (\Sigma, \{S, V\}, \{S \rightarrow aXa \mid bXb, X \rightarrow aX \mid bX \mid \varepsilon\}, S)$,

- $\mathcal{G}_3(\Sigma, \{S, X\}, \{S \rightarrow X, X \rightarrow S\}, S)$.
- 2. — $\mathcal{G}_4 = (\Sigma, \{L, S, X\}, \{S \rightarrow LX, L \rightarrow a \mid b, X \rightarrow LLX \mid \varepsilon\}, S)$,
- $\mathcal{G}_5 = (\Sigma, \{S, X\}, \{S \rightarrow XaX, X \rightarrow aX \mid bX \mid \varepsilon\}, S)$,
- $\mathcal{G}_6 = (\Sigma, \{S, X\}, \{S \rightarrow aSa \mid bSb \mid X, X \rightarrow \varepsilon \mid a \mid b\}, S)$,
- *c.f. exercice 1.*
- 3. — $\mathcal{G}_8 = (\Sigma, \{S\}, \{S \rightarrow \varepsilon \mid aSb\}, S)$,
- $\mathcal{G}_9 = (\Sigma, \{S, X\}, \{S \rightarrow aSb \mid SX, X \rightarrow bX \mid \varepsilon\}, S)$,
- $\mathcal{G}_{10} = (\Sigma, \{S\}, \{S \rightarrow aSbb \mid Sb \mid \varepsilon\}, S)$
- 4. — $\mathcal{G}_{11} = (\Sigma, \{S \rightarrow aSb \mid bSa \mid aS \mid SS \mid \varepsilon\}, S)$,

4 Raisonner par induction sur une grammaire

1. Montrons le par induction.
 - **Cas $S \rightarrow aS$.** Soit $w = aw'$ un mot, où ba n'est pas un sous-mot de w' . Alors, ba n'est pas un sous-mot de $w = aw'$.
 - **Cas $S \rightarrow Sb$.** Soit $w = w'b$ un mot, où ba n'est pas un sous-mot de w' . Alors, ba n'est pas un sous-mot de $w = w'b$.
 - **Cas $S \rightarrow \varepsilon \mid a \mid b$.** Le mot ba n'est pas un sous-mot de a , ni de b , ni de ε .
2. Montrons, par double-inclusion, que $\mathcal{L}(\mathcal{G}) = \mathcal{L}(a^*b^*)$.

“ \supseteq ” Soit $w \in \mathcal{L}(a^*b^*)$. Il existe m et n deux entiers tels que $w = a^n b^m$. On applique la dérivation

$$\underbrace{S \Rightarrow aS \Rightarrow aaS \Rightarrow \dots \Rightarrow a^n S}_{n \text{ fois}} \Rightarrow \underbrace{a^n Sb \Rightarrow a^n Sbb \Rightarrow \dots \Rightarrow a^n Sb^m}_{m \text{ fois}} \Rightarrow a^n b^m.$$

“ \subseteq ” D'après la question 1, on a ce sens de l'inclusion.

5 Ambigüité

6 Langage de Dyck

1. On suppose ce langage reconnaissable par un automate à n états. On considère le mot $w = \binom{n}{\cdot}^n$, donc $|w| \geq n$. Ainsi, il existe x, y et z trois mots tels que $w = xyz$, $|xy| \leq n$, $y \neq \varepsilon$ et $\forall p \in \mathbb{N}$, $xy^p z \in \mathcal{L}(\mathcal{G})$. Soit alors $p \in \llbracket 1, n-1 \rrbracket$ et $q \in \llbracket 1, n-p \rrbracket$ tels que $x = \binom{p}{\cdot}^p$, $y = \binom{q}{\cdot}^q$ et $z = \binom{n-q-p}{\cdot}^{n-q-p}$. Ainsi, $xy \in \mathcal{L}(\mathcal{G})$, ce qui est absurde. On en déduit que $\mathcal{L}(\mathcal{G})$ n'est pas reconnaissable, il n'est donc pas régulier.
2. On pose $\mathcal{G} = (\Sigma, \{S\}, \{S \rightarrow (S) \mid SS \mid \varepsilon\}, S)$.
3. — On le montre par induction.
 - **Cas $S \rightarrow \varepsilon$.** On a $|\varepsilon|_{\zeta} = 0 = |\varepsilon|$.
 - **Cas $S \rightarrow (S)$.** Soit $u \in \mathcal{L}(\mathcal{G})$ avec $|u|_{\zeta} = |u| = n$. Ainsi, $|(u)|_{\zeta} = |(u)| = n+1$.
 - **Cas $S \rightarrow SS$.** Soient u et v deux mots de $\mathcal{L}(\mathcal{G})$ tels que $|u|_{\zeta} = |u| = n$ et $|v|_{\zeta} = |v| = m$. Alors, $|u \cdot v|_{\zeta} = |v \cdot u|_{\zeta} = n+m$.
 - Montrons par induction \mathcal{P}_u : « pour tout v préfixe de u , $|v|_{\zeta} \geq |v|$. »
 - **Cas $S \rightarrow \varepsilon$.** Le seul préfixe de ε est ε , et on a bien $|\varepsilon|_{\zeta} = 0 \geq 0 = |\varepsilon|$.
 - **Cas $S \rightarrow (S)$.** Soit u un mot de $\mathcal{L}(\mathcal{G})$ vérifiant \mathcal{P}_u . Soit v un préfixe de (u) . On procède par induction sur v .
 - **Cas $v = \varepsilon$ ou (\cdot) .** OK.
 - **Cas (\tilde{u}) ,** où \tilde{u} est un préfixe de u . Par hypothèse d'induction, $|\tilde{u}|_{\zeta} \geq |\tilde{u}|$ donc $|(\tilde{u})|_{\zeta} = |(\tilde{u})|$.
 - **Cas (u) .** Par hypothèse d'induction, $|u|_{\zeta} \geq |u|$ donc $|(u)|_{\zeta} \geq |(u)|$.
4. On note $\bar{w}^j = |w_{\llbracket 0, j \rrbracket}|_{\zeta} - |w_{\llbracket 0, j \rrbracket}|$. Alors les deux conditions se traduisent par $\bar{w}^{|w|} = 0$ et $\forall i \in \llbracket 0, |w| - 1 \rrbracket$, $\bar{w}^i \geq 0$.

7 Listes OCAML

On pose $\mathcal{G} = (\Sigma, \{S, L, B\}, \{S \rightarrow [L] \mid [], L \rightarrow B; L \mid B, B \rightarrow \text{true} \mid \text{false}\}, S)$.

8 Mots de ŁUKASIEWICZ

1. On a $\Sigma \cap \mathcal{L} = \{\square\}$, $\Sigma^2 \cap \mathcal{L} = \emptyset$ et $\Sigma^3 \cap \mathcal{L} = \{\square\square\square\}$.
2. Montrons que $\Sigma^{2N} \cap \mathcal{L} = \emptyset$, pour tout $N \in \mathbb{N}^*$. (Dans le cas $N = 0$, le seul mot est ε , et il n'est pas dans \mathcal{L} .) Soit $w \in \Sigma^{2N} \cap \mathcal{L}$. On sait que $-1 = \bar{w}^{|w|} = \bar{w}^{|w|-1} + \text{va}(w_{|w|}) \geq \text{va}(w_{|w|})$, d'où $w_{|w|} = \square$, et $\bar{w}^{|w|-1} = 0$. On pose $w = u \cdot \square$, le mot u est donc de longueur impaire. Or, la somme $\sum_{k=1}^{|u|} \text{va}(u_k)$ est une somme d'un nombre impaire de termes valant -1 ou 1 , elle ne peut pas être nulle. Mais, comme $\bar{w}^{|w|-1} = 0$, donc elle est nulle, une contradiction. On en déduit que $\mathcal{L} \cap \Sigma^{2N} = \emptyset$. Par suite, on conclut que \mathcal{L} ne contient pas de mots pairs.
3. On suppose \mathcal{L} reconnaissable par un automate \mathcal{A} à n états. On considère le mot $w = \circ^n \cdot \square^n \cdot \square \in \mathcal{L}$. Alors, par application du lemme de l'étoile à l'automate \mathcal{A} avec ce mot w , il existe donc x, y et z trois mots de Σ^* tels que $w = xyz$, $|xy| \leq n$, $y \neq \varepsilon$ et, pour tout $p \in \mathbb{N}$, $xy^p z \in \mathcal{L}$. D'où, $x = \circ^k$, $y = \circ^j$ et $z = \circ^{n-k-j} \cdot \square^{n+1}$, où k et j sont des entiers. De plus, $j \neq 0$ car, sinon, $y = \varepsilon$. Alors, $xy^p z \in \mathcal{L}$, pour tout $p \in \mathbb{N}$. En particulier, pour $p = 0$, $xz \in \mathcal{L}$. Or, $xz = \circ^{n-j} \cdot \square^{n+1} \notin \mathcal{L}$ car $\bar{xz}^{|xz|} = (n-j) - (n+1) = -j-1 \neq -1$ car $j \neq 0$. On en déduit donc que \mathcal{L} n'est pas reconnaissable par un automate à n états. Ceci étant vrai pour tout n , alors \mathcal{L} n'est pas un langage régulier.

4.

```

1 let est_luka (w: word): bool =
2   let l = List.map va w in
3   let rec aux (l: int list) (s: int): bool =
4     match l with
5     | [] -> s = -1
6     | x :: q -> s >= 0 && aux q (s + x)
7   in aux l 0

```

CODE 1 – Fonction est_luka testant si w est un mot de Łukasiewicz

5. Soit $w = u \cdot v \in \mathcal{L}$, où $u \neq \varepsilon$ est un préfixe strict de w . Alors, $0 \leq \bar{w}^{|u|} = \bar{u}^{|u|} \neq -1$ donc $u \notin \mathcal{L}$.
6. Soient u et v deux mots de \mathcal{L} . On pose $w = \circ \cdot u \cdot v$. Montrons que $w \in \mathcal{L}$. On pose $n = |u|$, et $m = |v|$.
 - On a $\bar{w}^0 = 0 \geq 0$,
 - et $\bar{w}^1 = \text{va}(\circ) = 1 \geq 0$,
 - et, pour tout $i \in \llbracket 1, n \rrbracket$, $\bar{w}^{i+1} = \bar{u}^i + \text{va}(\circ) \geq \text{va}(\circ) \geq 0$,
 - et, pour tout $i \in \llbracket 1, m \rrbracket$, $\bar{w}^{i+n+1} = \bar{u}^n + \bar{v}^i + \text{va}(\circ) = \bar{v}^i \geq 0$,
 - et finalement, $\bar{w}^{n+m+1} = \bar{u}^n + \bar{v}^m + \text{va}(\circ) = -1 - 1 + 1 = -1$.

On en conclut que $w \in \mathcal{L}$.

7. Soit $w \in \mathcal{L}$, un mot de taille n . Comme montré précédemment, $\bar{w}^{n-1} = 0$. Ainsi, l'ensemble $\{k \in \llbracket 1, n \rrbracket \mid \bar{w}^k = 0\}$ est une partie de \mathbb{N} non vide, elle admet donc un minimum que l'on notera k . De plus, on a montré que $w_0 = \circ$. On en déduit que w peut être décomposé en

$$w = \circ \cdot \underbrace{w_2 w_3 \dots w_k}_u \cdot \underbrace{w_{k+1} w_{k+2} \dots w_n}_v \cdot$$

Montrons que u et v sont des mots de \mathcal{L} . D'une part, pour $i \in \llbracket 1, k-2 \rrbracket$, $0 < \bar{w}^{i+1} = \bar{u}^i + \text{va}(\circ)$, d'où $\bar{u}^i \geq 0$. De plus, $0 = \bar{w}^k = \bar{u}^{k-1} + \text{va}(\circ)$, d'où $\bar{u}^{k-1} = \bar{w}^k = -1$. Également, pour $i \in \llbracket 1, n-k-1 \rrbracket$, $0 \leq \bar{w}^{k+i} = \bar{w}^k + \bar{v}^i = \bar{v}^i$. Finalement, $-1 = \bar{w}^n = \bar{w}^k + \bar{v}^{n-k} = \bar{v}^{|v|}$. On en conclut que u et v sont bien des mots de \mathcal{L} .

Montrons, à présent, l'unicité de la décomposition. On suppose qu'il existe u' et v' deux mots de \mathcal{L} tels que $w = \circ \cdot u' \cdot v'$. Nous savons, en particulier, que $\bar{w}^{1+|u'|} = 0$, afin de

maintenir la condition $u \in \mathcal{L}$. Alors, $1 + |u'| \leq p$, et donc $|u'| \geq |u|$. Le mot u' est donc un préfixe de u . Au vu de la question 5., afin que u' soit un mot de \mathcal{L} , il est nécessaire que u' ne soit pas un préfixe strict de u . On en déduit que $u' = u$.

8. On utilise habilement la question précédente, et on pose

$$\mathcal{G} = (\{L\}, \Sigma, \{L \rightarrow \circ LL \mid \circ\}, L).$$

La question précédente montre la non-ambiguïté de la grammaire, et que $\mathcal{L}(\mathcal{G}) = \mathcal{L}$.

- 9.