

Module Langages Formels

TD 7 : Lemme de l'étoile et Lemme d'Ogden

Exercice 1 Lemme de l'étoile

Lemme (de l'étoile) :

Si L est un langage algébrique, alors il existe $N \in \mathbb{N}$ tel que $\forall u \in L, |u| \geq N \Rightarrow \exists x, v, y, w, z \in \Sigma^*, u = xvywz$ et

- $vw \neq \varepsilon$;
- $|vyw| \leq N$;
- $\forall i \geq 0, xv^i y w^i z \in L$

Montrer que les langages suivants ne sont pas algébriques.

1. $L_1 = \{a^i b^j c^k, i < j < k\}$;
2. $L_2 = \{a^n b^n c^m, n \leq m \leq 2n\}$;
3. $L_3 = \{a^{2^n}, n \geq 0\}$;
4. $L_4 = \{a^{n^2}, n \geq 0\}$;

Exercice 2 Lemme d'Ogden

L'objectif de cet exercice est de montrer une version plus forte du lemme de l'étoile pour les langages algébriques :

Lemme (Ogden) :

Soit L un langage algébrique. Il existe un entier N tel que pour tout mot $z \in L$ dans lequel on marque au moins N positions distinctes, il est possible de décomposer z sous la forme $z = uxv y w$ avec

- x ou y contient au moins une position marquée,
- $xv y$ contient au plus N positions marquées,
- pour tout $i \geq 0, ux^i v y^i w \in L$.

2.1. On se donne une grammaire algébrique propre G engendrant un langage L . Montrer qu'il existe une grammaire sous forme normale de Chomsky (CNF) reconnaissant le langage $L - \{\varepsilon\}$.

Rappel : Une grammaire CNF est une grammaire où les productions sont toutes de la forme

$$A \rightarrow BC \quad \text{ou} \quad A \rightarrow a$$

Définition:

Soit T un sous-arbre d'un arbre de dérivation selon une grammaire CNF. On suppose marquées certaines feuilles de T . On appelle *embranchement* un nœud de T ayant deux fils, tel que chacun de ses fils contienne au moins une feuille marquée.

2.2. Soit T un sous-arbre d'un arbre de dérivation selon une grammaire CNF. On suppose qu'au moins 2^h feuilles distinctes de T ont été marquées.

Montrer qu'il existe un chemin, d'une feuille à la racine, passant par au moins h embranchements et tel que pour tout i , le i -ème embranchement ait au plus 2^i descendants marqués.

2.3. On considère une grammaire CNF G engendrant le langage L . Montrer qu'il existe un entier N tel que :

- pour tout mot $w \in L$ dans lequel on marque au moins N positions,
- pour tout arbre de dérivation de w ,

il existe deux embranchements b_1 et b_2 tels que

- b_1 est un ancêtre de b_2 ,
- b_1 est un ancêtre d'au plus N feuilles marquées,
- b_1 et b_2 sont étiquetés par la même variable.

2.4. En déduire le lemme d'Ogden.

2.5. On s'intéresse au langage $L_5 = \{a^i b^j c^k d^l \mid i = 0 \text{ ou } j = k = l\}$.

2.5. 1. Montrer que pour tout $N \in \mathbb{N}^+$ et tout mot $z \in L_5$ avec $|z| \geq N$, il existe une décomposition $z = uvxyw$ telle que

- $|xy| \geq 1$
- $|xvy| \leq N$
- pour tout $i \geq 0$, $ux^i v y^i w \in L_5$.

2.5. 2. Montrer que L_5 n'est pas algébrique.