

C'est un analogue du lemme de l'étoile pour les langages algébriques plutôt que rationnels.

Lemme d'Ogden

Soit  $L$  le langage algébrique engendré par la grammaire algébrique  $G=(\Sigma, \Gamma, R)$  ie  $L = \widehat{L_G}(S)$  pour un certain  $S \in \Gamma$ .

Il existe alors  $N \in \mathbb{N}$  tel que pour tout mot  $f \in L$  contenant au moins  $N$  lettres distinguées, il existe une factorisation de  $f = \alpha u \beta v \gamma$  vérifiant:

(1) il existe  $T \in \Gamma$  tel que 
$$\begin{cases} S \xrightarrow{G^*} \alpha T \gamma \\ T \xrightarrow{G^*} u T v \\ T \xrightarrow{G^*} \beta \end{cases}$$


(2)  $\alpha, u$  et  $\beta$  contiennent des lettres distinguées  
ou  $\beta, v$  et  $\gamma$

(3)  $u \beta v$  contient moins de  $N$  lettres distinguées

Rq La condition (1) implique notamment que  $\{ \alpha u^m \beta v^m \gamma \mid m \in \mathbb{N} \} \subset L$ .  
En quelque sorte  $u$  et  $v$  sont des facteurs co-itérants.

Preuve Notons  $m$  la longueur maximale des membres droits des règles de la grammaire.

Un mot  $f$  de  $\widehat{L_G}(S)$  est la frontière d'un arbre de dérivation, dont la racine est étiquetée par  $S$  et dont le degré est  $m$ . En effet chaque nœud étiqueté par un non terminal a autant de fils que le membre droit (de la règle utilisé) a de terme, tandis que les nœuds étiquetés par des terminaux sont des feuilles.

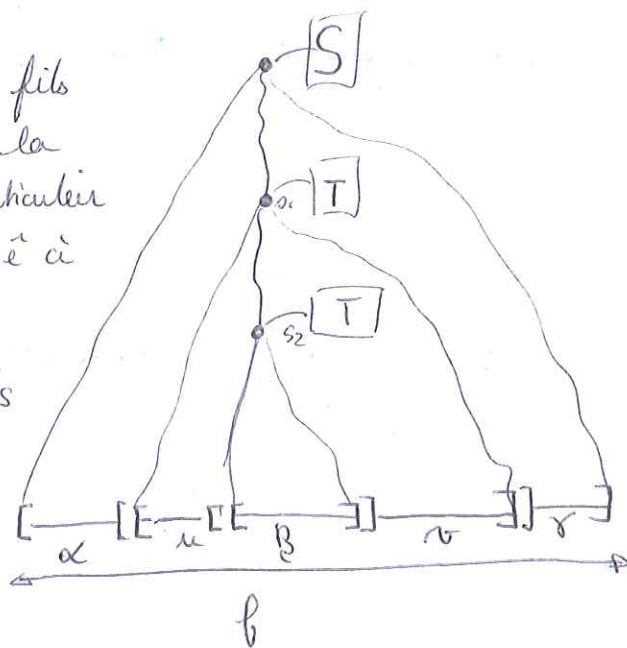


Les feuilles de cet arbre correspondent chacune à des lettres de  $f$ , on peut donc considérer distinguées les feuilles de l'arbre correspondant à des lettres marquées de  $f$ . Dès lors on sait que si  $f$  a  $k$  feuilles marquées avec  $k \geq m^r + 1$ , nécessairement une branche de cet arbre a plus de  $r$  sommets particuliers, par contreposé du

lemme: Si aucune branche d'un arbre de degré  $m$  n'a plus de  $r$  sommets particuliers, alors il y a moins de  $m^r$  feuilles dist.

En particulier pour  $r = \#V$  le nombre de non terminaux, on sait qu'une branche de cet arbre présente deux sommets particuliers  $s_1$  et  $s_2$  étiquetés par le  $m$  non terminal  $T$ .

Un sommet particulier a au moins deux fils distingués, dont l'un au plus est sur la branche considérée. Donc chaque nœud particulier a au moins un fils distingué qui peut être à droite ou à gauche de la branche. En considérant l'aîné de ses fils distingués (le  $+$  à gauche) on dira qu'un nœud part. est de type droit si ce fils est à droite de la branche et qu'il est de type gauche sinon.



Parmi les  $r+1$  sommets particuliers de la branche considérée, ou bien il y en a plus de type gauche, ou bien il y en a plus de type droit. Ainsi en posant  $\lambda = 2 \times \max(\#V, 2)$ , on sait qu'il y a une branche où il y a soit au moins  $\max(\#V, 2) + 1$  nœuds part. de type gauche soit droit.

On choisit alors pour  $s$  et  $t$  les deux plus bas.

En se rappelant que  $W \xrightarrow{G^*} w$  où il existe un arbre de dérivation de  $G$  de frontière  $w$  et dont la racine est étiquetée par  $W$  et en considérant ici les arbres respectivement issus de  $s_2, s_1$  et la racine (arbres de dérivation partiellement tronqués sous  $s_2$ , resp. sous  $s_1$  pour les 2 derniers) on est assuré que  $S \xrightarrow{G^*} \alpha T \gamma$ ;  $T \xrightarrow{G^*} \mu T \nu$  et  $T \xrightarrow{G^*} \beta$ . D'où (1).

• Si il y a  $\max(\#V, 2) + 1$  nd. part de type gauche, alors  $\alpha, \beta$  et  $u$  contiennent des lettres distinguées.

↳  $\beta$  car  $s_2$  est distingué, donc a des descendants feuilles qui le sont

↳  $u$  car  $s_1$  est de type gauche et a donc un fils distingué dont toutes les feuilles descendantes sont dans  $u$

↳  $\alpha$  car il y a forcément un autre sommet part de type gauche sur la partie de la branche entre la racine et  $s_1$ .

(NB: c'est pour assurer cela qu'on a pris  $\max(\#V, 2)$ )

• Si il y a  $\max(\#V, 2) + 1$  nd. part de type droit, alors  $\beta, v$  et  $\gamma$  contiennent des lettres distinguées, pour les mêmes raisons.

D'où (2).

Puisque soit  $\alpha$  soit  $\gamma$  contiennent des lettres distinguées,  $f' = u\beta v$  contient strictement moins de lettres distinguées que  $f$  et on peut lui réappliquer ce qu'on vient de faire.

En itérant on arrive à  $u^{(n)}\beta^{(n)}v^{(n)}$  qui contient moins de  $N$  lettres distinguées, reste alors à poser

$$\begin{aligned} \tilde{\alpha} &= \alpha' \alpha'' & \tilde{\beta} &= \beta^{(n)} \\ \tilde{\gamma} &= \gamma^{(n)} & \tilde{u} &= u^{(n)} \\ & & \tilde{v} &= v^{(n)} \end{aligned}$$

ainsi la décomposition  $f = \tilde{\alpha}\tilde{\beta}\tilde{v}\tilde{\gamma}$  convient, pour  $N = \underline{m^{\max(\#V, 2)}}$

D'où (3)

Cor [Bar-Hillel, Perles, Shamir]

Si  $L$  est un langage algébrique alors il existe un entier  $N \in \mathbb{N}$  tel que pour tout mot  $f \in L$  de longueur  $\geq N$ ,  $f$  admet une décomposition en  $f = \alpha u \beta v \gamma$  tel que  $\forall n \in \mathbb{N}, \alpha u^n \beta v^n \gamma \in L$

ex  $L_1 = \{a^n b^n c^n \mid n \in \mathbb{N}\}$  sur  $\Sigma = \{a, b, c\}$  n'est pas algébrique.

Par l'absurde supposons que  $L_1$  soit algébrique.

Il est alors engendré par une grammaire  $G$ , et d'après le lemme d'Ogden un certain entier  $N$  est associé à cette grammaire.

On considère alors  $f = a^N \underline{b^N} c^N$ ,  $f \in L_1$ . On distingue dans  $f$  toutes les occurrences de  $b$ , soit  $N$  lettres.

D'après le lemme d'Ogden il existe une factorisation de  $f$  en  $\alpha u \beta v \gamma$  tq  $\rightarrow \alpha, u, \beta$  ou  $\beta, v, \gamma$  contiennent des lettres dist.  
( $\rightarrow u \beta v$  contient moins de  $N$  lettres dist.)  
 $\rightarrow \forall n \in \mathbb{N} \alpha u^n \beta v^n \gamma \in L_1$ .

• Si  $\alpha, u$ , et  $\beta$  contiennent des lettres dist. c-à-d des  $b$ .

$\rightarrow \alpha$  s'achève après tous les  $a$ , après le début des  $b$   $\tilde{m}$ .

$\rightarrow \beta$  commence avant la fin des  $b$ .

Donc  $u$  n'est constitué que de  $b$ , et  $v$  ne contient aucun  $a$ .

De ce fait itérer simultanément  $u$  et  $v$  fait varier le nb de  $b$ , sans faire varier celui de  $a \rightarrow$  on sort de  $L_1$ . IMP

• Si  $\beta, v$  et  $\gamma$  contiennent des lettres dist. alors  $u$  est constitué que de  $b$  tandis que  $v$  ne contient aucun  $c$ , on a le  $\tilde{m}$  pb IMP.

D'où  $L_1$  n'est pas algébrique.