

## PLUS COURTE DÉRIVATION

Idée

Le but est de se donner, en fonction d'une grammaire et d'un texte / mot, une borne sur la longueur des dérivation - à tester - avant de conclure si oui ou non ce mot est engendré par cette grammaire.

Pl'

Soit  $G = (\Sigma, \Gamma, R, S)$  une grammaire algébrique.

Soit  $t = t_1 \dots t_n$  un mot de  $\Sigma^+$ .

Notons  $m$  le nombre maximal de symboles dans les termes droits des règles de  $G$  (s'il est supérieur à 2)

$t \in \mathcal{L}(G) \Leftrightarrow$  il existe une dérivation de  $S$  à  $t$  dans  $G$   
de longueur  $\leq \underline{m^{(2+n) \times |\Gamma|}}$

Rappelons qu'une dérivation de  $S$  à  $t$  dans  $G$  correspond à un arbre de dérivation, dont la racine  $r$  est étiquetée par  $S$  et les feuilles par des lettres de  $\Sigma$  ou par  $\epsilon$  de telle sorte que la concaténa-tion de leurs étiquettes de gauche à droite (la frontière de l'arbre) soit le mot  $t$ . Le nombre de dérivation correspond alors au nombre de noeuds internes.

Considérons l'arbre d'une plus courte dérivation dans  $G$  de  $S$  à  $t$ .  
Pour  $i \in [1..n]$ , une feuille correspond à la lettre  $t_i$ , non seulement elle est étiquetée par la lettre  $t_i$ , mais c'est aussi la  $i$ -ème feuille étiquetée par une lettre en partant de la gauche.

Pour chaque sommet de l'arbre on peut regarder la frontière des sous-arbre qu'il engendre. Cette frontière est un mot sur  $\Sigma$ , un facteur de  $t$  même. On affectera le sommet d'un attribut supplémentaire : son rang, défini comme la longueur de ce mot qu'il "couvre".

En particulier  $\rightarrow \text{rg}(f_i) = 1$

$\rightarrow \text{rg}(r) = |t|$  où  $r$  est la racine

$\rightarrow \text{rg}(\pi(s)) \geq \text{rg}(s)$  où  $s$  est un sommet quelconque et  $\pi(s)$  son père.

En considérant les sommets que l'on croise en remontant la branche de fi à r, le rang ne fait donc que croître, et comme il passe de 1 à |t| il ne peut croître strictem<sup>t</sup> que |t|-1 fois.

On partage cette branche en blocs de sommets selon leur rang. On vient de dire qu'il y a au plus |t| blocs.

Hormis la feuille tous les sommets sont des nœuds internes étiquetés par des non terminaux, c-à-d. des élém<sup>t</sup> de  $\Gamma$ .

Chaque bloc a au plus | $\Gamma$ | nœuds (internes). En effet si un bloc a plus de | $\Gamma$ | nœuds, il en présente deux de m<sup>ê</sup> étiquette, disons  $s_1$  et plus bas  $s_2$ . Comme le rang ne change pas entre  $s_1$  et  $s_2$  les sommets intermédiaires ne produisent aucune lettre; on pourrait donc recoller le sous arbre engendré par  $s_2$  sous  $s_1$ , sans changer la frontière, en gardant un arbre de dérivation dans  $G$ . Cela nie la minimalité en nombre de nœuds / nbre de dérivations. IMPOSSIBLE

Donc une branche menant à une feuille étiquetée par une lettre a au plus | $\Gamma$ | x |t| nœuds internes.

Pour une branche menant à une feuille étiquetée par  $\epsilon$ , on fait le m<sup>ê</sup> raisonnement sauf que, puisque le rang de la feuille est nul, il y a au plus |t|+1 blocs et donc au plus | $\Gamma$ | x (|t|+1) nœuds internes.

Cela borne la profondeur de l'arbre par  $\frac{(|\Gamma| \times (|t|+1)) - 1}{m}$

Il y a 1 nœ. de prof. 0 (la racine)

Il y a au + m \_\_\_\_\_ 1 (ses fils)

\_\_\_\_\_  $m^2$  \_\_\_\_\_ 2

\_\_\_\_\_  $m^{n-1}$  \_\_\_\_\_ n-1.

Au total il y a au plus  $\sum_{i=0}^{n-1} m^i$  nœds. (internes)


$$\text{or } \sum_{i=0}^{n-1} m^i = \frac{(1-m^n)}{(1-m)} = m^n \left( \frac{1/m^n - 1}{1-m} \right) \quad \text{car } m \geq 2$$

$$= \left( \frac{1 - 1/m^n}{m-1} \right) m^n \leq 1$$

Donc un nombre de dérivation minimal en  $m$  est  $(|t|+1) \times |\Gamma|$

ex  $G: S \rightarrow A \quad m=2$   
 $A \rightarrow aB | \epsilon \quad |\Gamma|=3$   
 $B \rightarrow b | S$

$t = aa \quad |t|=2$



Req on voit bien que le |t|+1 est néc. ici sur la branche qui va de S à  $\epsilon$ . il y a  $8 > |\Gamma| \times |t| = 6$  nœds internes.