


10 - Clôture des langages hors-contexte



1

Rappel

La classe des langages hors-contexte est **close** pour :

- l'**union**
- la **concaténation**
- l'**opération « étoile »**

La classe des langages hors-contexte **n'est pas close** pour :

- l'**intersection**
- le **complémentaire**

Cela dit :

Théorème l'intersection d'un langage hors-contexte et d'un langage rationnel est **hors-contexte**

On pourrait ajouter :

Théorème (admis) le complémentaire d'un langage hors-contexte reconnu par un AP **déterministe** est un langage hors-contexte.

2

Des langages qui ne seraient pas HC ?

- les langages hors-contexte sont engendrés par les grammaires hors-contexte et reconnus par la classe des automates à pile **non-déterministes**
- **tout langage est-il hors-contexte (= algébrique) ?**
- l'ensemble des langages **hors-contexte** sur un alphabet donné est **dénombrable**

Une grammaire peut être perçue comme un simple mot un alphabet qui serait la réunion de ses ensembles de terminaux et de non-terminaux, auquel on ajoute un nombre fini de symboles utilitaires. Cet ensemble de mots est dénombrable.

Rappel Cours 1 : l'ensemble des langages sur un alphabet donné **n'est pas dénombrable**

Conclusion : il existe des langages qui ne sont pas hors-contexte ...

3

Problème



- **Donnée :** L un langage
- **Problème :** L est-il hors-contexte ?


En fait, existe-t-il un analogue au lemme de l'étoile pour les langages hors-contexte ?

- pour les langages rationnels, on a utilisé le **principe des tiroirs** appliqué au **nombre d'états** d'un automate fini
- pour les langages hors-contexte, on utilise ce même principe sur les **étiquettes des nœuds de l'arbre syntaxique**

idée : un arbre de dérivation suffisamment haut va contenir plusieurs sous-arbres avec le même non-terminal en racine car les non-terminaux de la grammaire sont en **nombre fini**.

4

Idée



5

Lemme de l'étoile*



- Lemme** si L est un langage hors-contexte, il existe un entier n ne dépendant que de L tel que :
- > pour tout mot μ de L de longueur $\geq n$,
 - > il existe une factorisation de μ en $uvwx$ telle que :
- $|vx| > 0$ et $|w| > 0$
 - $|vwx| \leq n$
 - $\forall i \geq 0, u v^i w x^i y \in L$

* Pumping lemma en anglais, aussi appelé lemme de la pompe ou lemme du gonflement.

6

Lemme de l'étoile*



- Lemme** si L est un langage hors-contexte, il existe un entier n ne dépendant que de L tel que :
- > pour tout mot μ de L de longueur $\geq n$,
 - > il existe une factorisation de μ en $uvwx$ telle que :
- $|vx| > 0$ et $|w| > 0$
 - $|vwx| \leq n$
 - $\forall i \geq 0, u v^i w x^i y \in L$

- comme pour les langages rationnels, le lemme de l'étoile sert à montrer qu'un langage n'est pas hors-contexte

ce lemme n'est pas une caractérisation : certains langages non HC vérifient les propriétés du lemme

- on suppose par l'absurde qu'un langage L est hors-contexte puis on cherche une contradiction

* Pumping lemma en anglais, aussi appelé lemme de la pompe ou lemme du gonflement.

7


Démonstration

- soit L un langage (supposons $L = L \setminus \{\epsilon\}$) et G une grammaire hors-contexte sous F.N. de Chomsky pour L ayant k non-terminaux
- prenons $\mu \in L$ de longueur $|\mu| \geq n = 2^k$
- A_μ est l'arbre syntaxique associé à μ
- fait (à montrer par simple récurrence) :
si A_μ a tous ses chemins de longueur $\leq i$, $|\mu| \leq 2^{i-1}$
- comme $|\mu| > 2^{k-1}$, A_μ a un chemin C de longueur maximale au moins égale $k+1$
- ce chemin C comporte au moins $k+2$ nœuds tous étiquetés par des non-terminaux sauf sa feuille, étiquetée par un terminal
- donc il existe un non-terminal A apparaissant au moins 2 fois dans C et il existe deux nœuds n_1 et n_2 de C qui vérifient :
 - n_1 et n_2 ont la même étiquette A
 - n_1 est plus proche de la racine que n_2
 - le chemin de n_1 à la feuille est de longueur au plus $k+1$.

8

Démonstration (fin)

- A_1 engendre un facteur z de longueur $\leq 2^k$
car les chemins de n_1 aux feuilles de longueur au plus $k+1$
- A_2 engendre w , un sous-facteur de $z = vwx$
- v et x ne peuvent être simultanément égaux à ε :
il existe dans A_1 une règle $B \rightarrow CD$ telle que
 C et D engendrent resp. v et wx (ou bien vw et x)
or ni C ni D ne peut se dériver dans le vide
- w est différent de ε
- on a $A \Rightarrow^* vAx$ et $A \Rightarrow^* w$
- on constate que pour tout $i \geq 0$:
 $A \Rightarrow^* v^i w x^i$
- on obtient une factorisation de μ en $uvwxy$ telle que
 $x v^i w x^i y \in L$ pour tout $i \geq 0$



9

En pratique

- on suppose par l'absurde que L est hors-contexte
- le lemme devrait être vérifié pour un entier n
- s'il existe un mot μ de L de longueur $\geq n$ tel que :
quelle que soit la décomposition de μ en $uvwxy$
vérifiant :
 - $|vwx| > 0$ et $|w| > 0$
 - $|vwx| \leq n$
- si on trouve un $i \geq 0$ tel que :
 $u v^i w x^i y \notin L$
- alors :
→ on peut conclure que L n'est pas hors-contexte.

10

Exemple

Supposition : le langage $L = \{0^i 1^i 2^i, i > 0\}$ est hors-contexte

- le lemme est vérifié pour un n fixé (même si on ignore sa valeur)
- considérons $\mu = 0^n 1^n 2^n \in L$
- pour toute factorisation de $\mu = uvwxy$ avec $|vwx| > 0$, $|w| > 0$ et $|vwx| \leq n$
- $|vwx| \leq n \Rightarrow vx$ ne peut contenir à la fois des 0 et des 2
 - prenons $i = 0$
 - au moins un symbole parmi 0, 1 ou 2 va voir son nombre diminuer
 - au moins un symbole parmi 0, 1, 2 va voir son nombre rester intact
- cela entraîne que $z_0 = u v^0 w x^0 y = uwy \notin L$
- ainsi, pour toute factorisation de μ vérifiant les 3 conditions,
on a trouvé un i tel que $z_i = u v^i w x^i y$ n'est pas dans L
- contradiction avec le lemme : notre supposition est fautive !

Conclusion : L n'est pas hors-contexte.


11

Une grammaire contextuelle*

$G = (N, T, P, S)$

- S axiome
- $N = \{S, T\}$
- $T = \{0, 1, 2\}$

- $P = \left\{ \begin{array}{l} S \rightarrow 0ST \mid 012 \\ 2T \rightarrow T2 \\ 1T2 \rightarrow 1122 \end{array} \right\}$



Ce langage $L(G)$ est donc contextuel.

* context-sensitive en anglais

12

Grammaires HC et indécidabilité

- un **problème de décision** est **indécidable** s'il n'existe pas de *procédure effective* (disons pour l'instant d'algorithme) qui donne la réponse **oui** ou **non** en un temps fini
- soient G et G' deux grammaires hors-contexte sur le même alphabet de terminaux T, les problèmes suivants sont **indécidables** :
 - $L(G) \cap L(G') = \emptyset$?
 - $L(G) = L(G')$?
 - $L(G) = T^*$?
 - G est-elle ambiguë ?