

Insuffisance des langages rationnels : $\{a^n b^n\}$ n'est pas reconnaissable par automate !

Grammaires hors contexte et langages algébriques.

Def 1 : Une grammaire hors contexte (algébrique) est un quadruplet (V, T, R, S) vérifiant :

- V , l'ensemble des variables, est fini (on notera ses éléments en majuscule).
- T , l'ensemble des terminaux, est fini (éléments notés en minuscule), avec $V \cap T = \emptyset$.
- $S \in V$ est le symbole de départ.

- R est un ensemble de règles : $R \subseteq V^* (VUT)^*$. On notera, pour $(X, u) \in R$, $X \rightarrow u$. X est le membre de gauche et le mot u sur l'alphabet (VUT) est le membre de droite.

Exemple 1 : $T = \{a, b\}$, $V = \{S\}$, $R = \{S \rightarrow aSb, S \rightarrow \epsilon\}$.

Exemple 2 : $T = \{a, b\}$, $V = \{S\}$, $R = \{S \rightarrow aSa, S \rightarrow bSb, S \rightarrow \epsilon\}$.

Def 4 : Soit $G = (V, T, R, S)$ une grammaire algébrique, u et v deux mots sur $V + T$. On dit que u se dérive en v , noté $u \rightarrow v$, lorsque : $\exists \alpha, \beta \in (A + V)^*$, $X \in V$ tels que :

$$u = \alpha X \beta, \quad v = \alpha W \beta, \quad \text{et } X \rightarrow W \in R.$$

Remarque : L'appellation grammaire hors contexte est licite !

Def 5 : Un langage est dit algébrique si il est généré par une grammaire algébrique, id est : $L = \{v \in T^* ; S \xrightarrow{*} v\}$, où $G = (V, T, R, S)$ est une grammaire algébrique.

Exemple 6 : Le langage algébrique généré par la grammaire de l'exemple 2 est $\{a^n b^n, n \geq 0\}$, et celui de l'exemple 3 est $\{w w^R, w \in T^*\}$.

Théorème 7 (fondamental) : Soit $G = (V, T, R, S)$ une grammaire algébrique, u et v deux mots sur $(T + V)^*$. On suppose que u se factorise en $u = u_1 u_2$. Alors il existe une dérivation de longueur l : $u \xrightarrow{l} v$ si il existe une factorisation $v = v_1 v_2$ telle que :

$$u_1 \xrightarrow{l_1} v_1, \quad u_2 \xrightarrow{l_2} v_2 \quad \text{et } l_1 + l_2 = l.$$

Exemple 8 : G définie par $T = \{a, b\}$, S , $V = \{S, A\}$, $R = \{S \rightarrow SA + \epsilon, A \rightarrow aSb\}$, (langage de Dyck).

Langage algébrique.

Langage algébrique.

310

AA ne dérive pas $aabb$ avec $A \rightarrow ab$ et $A \rightarrow aabb$.

Def 9 : Une grammaire algébrique. Un arbre de dérivation est un arbre fini étiqueté par $VUTV$ vérifiant : si A est l'étiquette d'un noeud et a_1, \dots, a_n les étiquettes de tous ses fils, alors $A \rightarrow a_1 \dots a_n \in R$. La frontière de l'arbre est la concaténation de toutes les feuilles, de gauche à droite.

Exemple 10 : cf annexe 1.

Def 10 : Une grammaire G est dite ambiguë si il existe au moins un mot ayant au moins deux arbres de dérivation.

Exemple 11 : $V = \{S\}$, $T = \{a\}$, $R = \{S \rightarrow SS + a\}$. cf annexe 2.

Def 12 : Une grammaire G est dite propre si il n'existe aucune règle de la forme $A \rightarrow \epsilon$ ou $A \rightarrow B$ avec $A, B \in V$.

Exemple 13 : La grammaire de l'exemple 2 n'est pas propre, mais la suivante l'est : $R = \{S \rightarrow aSb + ab\}$. Ces langages reconnus sont les mêmes à ϵ près.

Def 14/Def 15 : Tout langage algébrique ne générant pas ϵ peut être engendré par une grammaire sous forme normale de Chomsky, c'est à-dire que toutes les productions sont de la forme $A \rightarrow B C$ ou $A \rightarrow a$.

Exemple 15 : $G = (\{S, A, B\}, \{a, b\}, A, S)$ avec les règles :

$S \rightarrow bAaB$	forme	$A \rightarrow B'A'' + A'S + a$
$A \rightarrow bAA + aS + a$	normale	$B \rightarrow A'B'' + B'S + b$
$B \rightarrow aBB + bS + b$	de Chomsky :	$B' \rightarrow b, \quad A' \rightarrow a, \quad B'' \rightarrow BB, \quad A'' \rightarrow AA$

Def 16 : Tout langage algébrique ne générant pas ϵ peut être engendré par une grammaire sous forme normale de Greibach, id est toutes les productions sont de la forme : $A \rightarrow a\alpha$, où $\alpha \in V^*$.

Exemple 17 (langage de Dyck généralisé) :

$G = (\{S, A\}, \{a_1, \bar{a}_1, \dots, a_n, \bar{a}_n\}, R, S)$, avec $R : \begin{cases} S \rightarrow SA + \epsilon \\ A \rightarrow a_1 S \bar{a}_1 + \dots + a_n S \bar{a}_n \end{cases}$	forme	$\begin{cases} S \rightarrow SA + \epsilon \\ A \rightarrow a_1 S \bar{a}_1 + \dots + a_n S \bar{a}_n \end{cases}$
	normale	$\begin{cases} S \rightarrow SA + \epsilon \\ A \rightarrow a_1 S \bar{a}_1 + \dots + a_n S \bar{a}_n \end{cases}$
	de Greibach :	$\begin{cases} S \rightarrow SA + \epsilon \\ A \rightarrow a_1 S \bar{a}_1 + \dots + a_n S \bar{a}_n \end{cases}$

II Propriétés générales des langages algébriques.

Déf 18: Système d'équation associé à une grammaire algébrique G :

Soit $n := |V|$, alors le système est constitué des n équations:

$$l_i = \sum_{X_i \rightarrow w} w(l), \text{ où } X_i \in V, \text{ en les variables } l_1, \dots, l_n. \quad (\text{noté } S_G)$$

Système 19: Soit $G = (V, T, R, S)$. Alors le langage généré par G est la solution minimale du système défini précédemment. $(*)$

Exemple 20: $\begin{cases} X_1 \rightarrow X_1 X_2 + \varepsilon \\ X_2 \rightarrow a X_2 + b \end{cases}$ donne le système $\begin{cases} l_1 = l_1 l_2 + \varepsilon \\ l_2 = a l_2 + b \end{cases}$

La solution minimale est: $\{\varepsilon\} \cup \{a+b\}^*$

Caractérisation des langages algébriques (conditions nécessaires):

Lemma 21 (Ggden): Soit $G = (V, T, R, S)$ et L le langage généré par V .

Il existe $K > 0$, telle que pour tout mot $f \in L$ avec $|f| > K$, il existe une factorisation $f = u v x y z$ avec $v \neq \varepsilon$, $|x| + y \leq K$ et $u \# v \# y \# z \in L$ pour tout $\# \geq 0$.

Exemple 22: $L = \{a^i b^j c^k \mid i \neq j \text{ et } i \neq k\}$ n'est pas algébrique.

Th 23 (Bar-Hillel; Sari Shamir): Les langages algébriques sont clos par substitution, union, concaténation (morphisme).

Th 24: Si L est algébrique et K est rationnel, alors $L \cap K$ est algébrique.

Th 25: La classe des langages algébriques n'est pas close par intersection!

Exemple 26: $L_1 = \{a^i b^i c^i, i \geq 1\}$ $L_2 = \{a^i b^i c^j, i \geq 1, j \geq 1\}$ algébriques
 $L_3 = \{a^i b^j c^j, i \geq 1, j \geq 1\}$ algébrique.

Le lemme d'Ggden montre que L_1 n'est pas algébrique, mais

$$L_2 = L_1 \cap L_3 !$$

Déf 27: Une grammaire étendue G est définie par (V, T, R, S) avec V et T deux alphabets finis disjoints, $R \subseteq V \times (T \cup V)^*$ telle que pour tout $X \in V$, $\{w \mid (X, w) \in R\}$ est rationnel.

Système 28: L'ensemble des mots engendrés par une grammaire étendue est algébrique.

Déf 29: On note \bar{L} l'image commutative d'un langage: $\bar{L} := \{\bar{w} \mid w \in L\}$,

où \bar{w} est la classe des anagrammes de w (on peut permettre les lettres). $(*)$

Th 30 (Parikh): Tout langage algébrique L est commutativement équivalent à un langage rationnel R (i.e. $\bar{L} = \bar{R}$). DVT

CAR
p 86

IV Automate à pile.

Déf 31: Un automate à pile est défini par un septuplet $M = (Q, \Sigma, \Gamma, \Delta, \delta, q_0, F)$:

Q est un ensemble fini d'états, Σ est l'alphabet d'entrée,

Γ est l'alphabet de pile, $\Gamma \subseteq Q$ est l'ensemble des états acceptants,

$q_0 \in Q$ est l'état initial, $\Delta \subseteq (Q \times \Sigma^* \times \Gamma^*) \times (Q \times \Gamma^*)$ est la relation de transition.

Déf 32: La configuration (q', w', α') est dérivable en une étape de la configuration (q, w, α) (notée $(q, w, \alpha) \xrightarrow{} (q', w', \alpha')$) si:

$w = u w'$, $\alpha = \beta \Gamma$ et $\alpha' = \gamma \Gamma$ (sur la pile),

$((q, u, \beta), (q', \gamma)) \in \Delta$

Déf 33: Une exécution d'un automate à pile sur un mot w est une suite de configurations (finie ou infinie):

$(q, w, \alpha) \xrightarrow{} (q_1, w_1, \alpha_1) \xrightarrow{} \dots \xrightarrow{} (q_n, w_n, \alpha_n) \xrightarrow{} \dots$

Déf 34: Un automate à pile acceptant un état final, accepte le mot w : si:

$(s, w, \alpha) \xrightarrow{}^* (p, \varepsilon, \Gamma)$, avec $p \in F$.

Déf 35: Un automate à pile acceptant une pile vide, accepte le mot w : si

$(s, w, \alpha) \xrightarrow{}^* (q, \varepsilon, \emptyset)$.

Déf 36: Un langage L est reconnu par un automate à pile M si et seulement si l'ensemble des mots acceptés par M est L .

Système 37: Un langage est reconnu par un automate acceptant un état final si et seulement il est reconnu par un automate acceptant sa pile vide. (cf annexe 3)

Exemple 38: $Q = \{s, p, q\}$ $\Sigma = \{a, b\}$ $\Gamma = \{A\}$ $F = \{q\}$ et

$\Delta = \{(s, a, \varepsilon) \rightarrow (s, A) ; (s, \varepsilon, \varepsilon) \rightarrow (q, \varepsilon) ; (s, b, A) \rightarrow (p, \varepsilon) ; (p, b, A) \rightarrow (p, \varepsilon) ; (p, \varepsilon, \varepsilon) \rightarrow (q, \varepsilon)\}$ reconnaît $\{a^n b^n\}$.

WOL
p 73

WOL
p 76

CAR
p 108

Th 33: Un langage L est algébrique si et seulement s'il est reconnu par un automate à pile.

Dif 40: Un automate à pile M est déterministe si pour toute paire $(q, \alpha) \in Q \times \Gamma$; soit il existe une unique transition $q, \alpha, \varepsilon \rightarrow q', \beta$ et il n'existe pas d'autre transition $q, \alpha, a \rightarrow q', \beta$, où $a \in \Sigma$; soit il n'existe pas de transition de la forme $q, \alpha, \varepsilon \rightarrow q', \beta$, et il existe au maximum un $a \in \Sigma$ tel que $q, \alpha, a \rightarrow q', \beta$.

Dif 41: Un langage algébrique est déterministe s'il est reconnu par un automate à pile déterministe acceptant un état final.

Prop 42: Le complémentaire d'un langage algébrique déterministe est un langage algébrique déterministe.

Prop 43: Si L est reconnu par un automate à pile déterministe acceptant, alors il est reconnu par un automate à pile déterministe sur pile vide acceptant un état final.

A) L'ancien programme n'est pas valable!

Prop 44: Tout langage algébrique déterministe est non ambigüe.

Exemple 45: $L_1 = \{w \in \overline{\omega}^R \mid w \in \{a, b\}^*\}$ est déterministe, mais (ADNIS) $L_2 = \{w \in \overline{\omega}^R \mid w \in \{a, b\}^*\}$ ne l'est pas.

IV Analyse syntaxique.

Une partie du travail effectuée par le compilateur: vérifier que la syntaxe est correcte que le mot appartient au langage.

Analyse descendante: on part d'un mot et de S , et on modifie S (ou la partie gauche dans l'exemple) avec les règles pour supprimer au fur et à mesure les lettres du mot.

Analyse ascendante: on essaie de réduire le mot de droite sur l'exemple, en utilisant les membres droits d'une dérivation.

analyse descendante LL

$$\begin{cases} S \rightarrow cT & (1) \\ T \rightarrow aTbc & (2) \\ T \rightarrow b & (3) \\ (S, cabbc) & \\ (T, cabbc) & (1) \\ (T, abbc) & \\ (cbTa, abbc) & (2) \\ (cbT, bbc) & \\ (cbb, bbc) & (3) \\ (cb, bc) & \\ (c, c) & \\ (,) & \end{cases}$$

analyse ascendante LR

$$\begin{cases} E \rightarrow E + T & (1) \\ T \rightarrow (E) & (2) \\ E \rightarrow T & (3) \\ T \rightarrow a & (4) \\ T \rightarrow b & (5) \\ (1, b + (a+a)) & \\ [b, + (a+a)] & \\ [T, + (a+a)] & (3) \\ [E, + (a+a)] & (3) \\ [E+, (a+a)] & \\ [E+(, a+a)] & \\ [E+(a, +a)] & \\ [E+(a, +a)] & \\ [E+(T, +a)] & (4) \\ [E+(E+T, ,)] & \\ [E+(E, ,)] & (1) \\ [E+(E), 1] & \\ [E+T, 1] & (2) \\ [E, 1] & (1) \end{cases}$$

Voici un algorithme qui teste l'appartenance d'un mot à un langage algébrique: l'algorithme Earley-Younger-Kasami

Th 46: Il existe un algorithme qui teste l'appartenance à un langage algébrique en temps $O(|w|^3)$. DVI

(*) Prop 19 bis: Soit une grammaire propre; alors L_G est l'unique solution propre de S_G .

(**) Prop 29 bis: Soit une grammaire; alors toute solution L propre du système S_G vérifie $L = L_G$.

H-U: Hopcroft - Ullman: Introduction to automata theory...
CAR: Burton, langages formels.

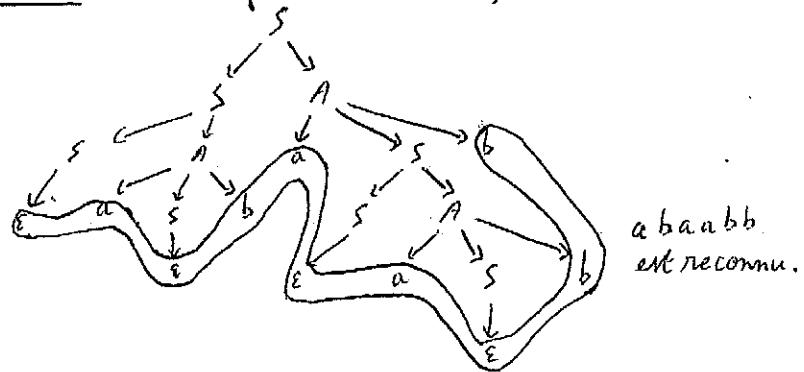
WOL: Wolper, introduction à la calculabilité.

AUT: Bouteiller, théorie des langages et des automates.

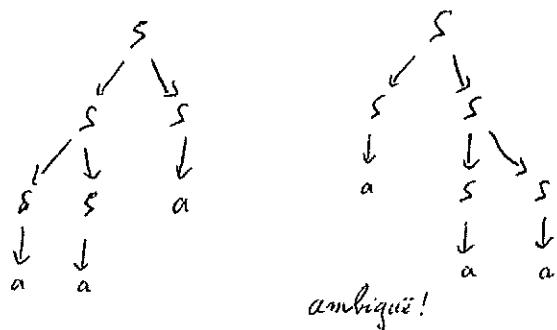
F.B.: Floyd-Sriegel, Le langage des machines.

FB
p 320

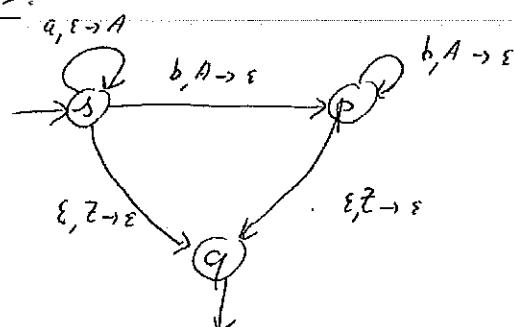
Annexe 1 : avec la grammaire de l'exemple 8,



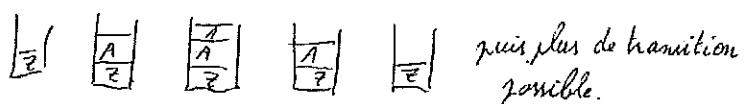
Annexe 2 :



Annexe 3 :



Pour reconnaître aabba, on a sur l'apil:



Théorème de Parikh

Soit L un langage algébrique sur un alphabet A , alors il existe R rationnel sur A tel que $\overline{L} = \overline{R}$ (où $\overline{\cdot}$ désigne l'image commutative)

Démonstration : on se permettra d'omettre le symbole de départ des grammaires manipulées

I) Lemme : soit G une grammaire propre, alors toute solution L de $\overline{S_G}$ vérifie $\overline{L} = \overline{L_G}$

II) Proposition : soit G une grammaire généralisée, alors le système S_G admet une solution rationnelle, i.e. si $G = (A, V, \overline{U}, \{N_i \rightarrow S_i(X)\})$, où $V = \{X_0, \dots, X_m\}$ et $X = (X_0, \dots, X_m)$, il existe un $n+1$ -tuple $R = (R_0, \dots, R_m)$ de langages rationnels sur A tel que $\overline{S_i(X)} \cap R_i = S_i(R)$

III) Conclusion

I) Il s'agit de la proposition 29 bis du plan. La preuve est essentiellement la même que celle de la proposition 19 bis (voir Corillon p. 95)

II) On raisonne par récurrence sur le nombre de non-terminants de G . Soit $\mathcal{P}(n)$: "Pour toute grammaire $G = (A, V, P)$ généralisée telle que $|V| = n$, $\overline{S_G}$ admet une solution rationnelle".

Montreons $\mathcal{P}(1)$: soit $G = (A, \{X\}, \{X \rightarrow S(X)\})$ une grammaire généralisée.

Soit $T = S(X) \cap A^*$ et $P(X) = S(X) \cap ((A+X)^* X (A+X)^*)$

On a donc $P(X) + T = S(X)$; $T \in \text{Rat}(A)$ et $P(X) \in \text{Rat}(A+X)$

Il existe $Q(X) \in \text{Rat}(A+X)$ tel que $\overline{P(X)} = \overline{Q(X)} X$ (par exemple on peut choisir Q formée des mots de P où première occurrence de X)

Le système S_G se réécrit alors, pour l'inconnue L :

$$\overline{L} = \overline{Q(L)L + T}$$

Soit donc $R = Q(T)^* T$, $R \in \text{Rat}(T)$ (car $Q(T)$ est l'image de $Q(X)$ par un morphisme rationnel)

$$\text{et } \overline{Q(R)R + T} = \overline{Q(Q(T)^* T)Q^* T + T} = \overline{(Q(T)Q^* T)^* + \varepsilon} T = \overline{Q(T)^* T} = \overline{R}$$

donc R est solution de $\overline{S_G}$, d'où $\overline{P(A)}$

Soit $n \geq 1$, on suppose $\mathcal{P}(k)$ pour $k \leq n$

Soit $G = (A, \{x_0, \dots, x_n\} = V, S = \bigcup_{i=0}^n \{x_i \rightarrow S_i(X)\})$ une grammaire généralisée à $n+1$ non-terminaux, où X désigne (x_0, \dots, x_n) .

On notera $V' = \{x_1, \dots, x_n\}$ et $X = (x_1, \dots, x_n)$.

On définit $G_0 = (A + V', \{x_0\}, \{x_0 \rightarrow S_0(X_0, X')\})$.

Par hypothèse de récurrence, S_0 admet une solution $R_0(X') \in \text{ERat}(A + V')$,

$$\text{i.e. } S_0(R_0(X'), X') = R_0(X') \quad (*)$$

Soit maintenant $G' = (A, V', \bigcup_{i=1}^n \{x_i \rightarrow S_i(R_0(X'), X')\})$

Par hypothèse de récurrence, S_i admet une solution nationnelle $R_i = (R_1, \dots, R_m)$

$$\text{i.e. } \forall i \in \{1, \dots, n\} \exists R_i \in \text{ERat}(A) \text{ et } R_i = \overline{S_i(R_0(R'), R')}$$

De plus, $(*)$ entraîne en particulier $\overline{S_0(R_0(R'), R')} = \overline{R_0(R')}$

et $R_0(X') \in \text{ERat}(A)$ on tant que l'image de $R_0(X')$ $\in \text{ERat}(A + V')$ par un morphisme

de $A + V'$ dans $\text{Rat}(A)$

donc $R = (R_0(R'), R')$ est solution nationnelle de $\overline{S_A}$, d'où $\mathcal{P}(n+1)$.

$\mathcal{P}(n)$ est vrai pour tout n , ce qui conclut la preuve de II)

III) : Soit L un langage algébrique sur un alphabet A .

Soit G une grammaire propre reconnaissant $L(\{e\})$, $G = (A, \{x_0, \dots, x_n\}, P, X_0)$

Alors si $L_A = (L_0, \dots, L_m)$, on a $L(\{e\}) = L_0$

Soit $R = (R_0, \dots, R_m)$ une solution nationnelle de $\overline{S_A}$. On a $\overline{R} = \overline{L_A}$.

donc en particulier $\overline{R_0} = \overline{L_0} = \overline{L(\{e\})}$

d'où $\overline{L} = \overline{R_0 + \varepsilon(L)}$, avec $R_0 + \varepsilon(L)$ national sur A .