

Cours de Langages formels

Laure Danthony - Marianne Delorme

Grammaires LL et LR

Introduction

Il existe deux types d'analyse ¹ :

- **L'analyse descendante** : à partir de l'axiome, on construit une dérivation du mot à analyser. Pour l'analyse *LL*, ces dérivations s'effectuent "le plus à gauche".
- **L'analyse ascendante** : on construit une dérivation qui commence par l'axiome (en partant de la fin) . Pour l'analyse *LR* ce sont des dérivations "le plus à droite".

REMARQUE 1 La lecture du mot se fait **toujours** de gauche à droite. D'où la signification du *L* de *LR* et *LL*.

Intuitivement, on note $L?(k)$ une grammaire si le test d'appartenance peut être réalisé avec k "look-ahead". C'est l'idée intuitive du formalisme qui va suivre.

1 Grammaires $LL(k)$

DÉFINITION 1

Si $|w| > k$, $k : w$ désigne le préfixe de longueur k du mot w , sinon $k : w$ désigne w lui-même.

DÉFINITION 2

Une grammaire algébrique $G = (\Sigma, N, P, S)$ est dite $LL(k)$, $k \geq 0$ lorsque la condition suivante est vérifiée :

$$\left\{ \begin{array}{l} (1) \quad S \xrightarrow{*}_g uA\theta \vdash u\alpha\theta \xrightarrow{*}_g uw \\ (2) \quad S \xrightarrow{*}_g uA\theta \vdash u\beta\theta \xrightarrow{*}_g uw' \Rightarrow \alpha = \beta \\ (3) \quad k : w = k : w' \end{array} \right.$$

REMARQUE 2 Une telle grammaire n'est pas ambiguë.

EXEMPLE 1

¹c'est à dire deux manières de savoir si $u \in L(G)$

- $\begin{cases} S \rightarrow aAb \mid b \\ A \rightarrow a \mid bSA \end{cases}$ est $LL(1)$.
- $\begin{cases} S \rightarrow \varepsilon \mid abA \\ A \rightarrow Saa \mid b \end{cases}$ est $LL(2)$.

REMARQUE 3 Un langage $LL(0)$ est soit vide soit réduit à une seule lettre.

EXERCICE 1 Montrez que les langages rationnels sont $LL(1)$

REMARQUE 4 Il existe des grammaires algébriques qui ne sont $LL(k)$ pour aucun k , par exemple :

- La grammaire : $\begin{cases} S \rightarrow A \mid B \\ A \rightarrow aAb \mid 0 \\ B \rightarrow aBbb \mid 1 \end{cases}$ qui décrit le langage $\{a^n 0 b^n\} \cup \{a^n 1 b^{2n}\}$
- La grammaire : $S \rightarrow b \mid S a$ qui décrit le langage $\{b a^n, n \geq 1\}$

2 Les fonctions $Premier_k$, $Suivant_k$

DÉFINITION 3

Soit $G = (\Sigma, N, P, S)$ une grammaire. Si $\alpha \in (\Sigma \cup N)^*$, on définit pour tout $k \geq 0$ les ensembles suivants :

- $Premier_k(\alpha) = \{k : w \mid \alpha \xrightarrow[G]{*} w\}$
- $Suivant_k(\alpha) = \{w \in \Sigma^* \mid \exists \beta, \gamma, S \vdash \beta\alpha\gamma \text{ et } w \in Premier_k(\gamma)\}$

DÉFINITION 4

Si L est un langage, on note :

$$Premier_k(L) = \bigcup_{\alpha \in L} Premier_k(\alpha) \text{ et } Suivant_k(L) = \bigcup_{\alpha \in L} Suivant_k(\alpha).$$

Nous allons maintenant énoncer différentes caractérisations des grammaires $LL(k)$:

PROPOSITION 1 Une grammaire algébrique est $LL(k)$ ssi pour toutes productions distinctes $A \rightarrow \alpha$ et $A \rightarrow \beta$, l'intersection des ensembles $Premier_k(\alpha\gamma)$ et $Premier_k(\beta\gamma)$ est vide, pour tout γ tel que $S \xrightarrow[G]{*} uA\gamma$ existe.

PREUVE :

- $: \Leftarrow$ Si G n'est pas $LL(k)$, d'après la définition, il existe $\alpha \neq \beta, \dots$ Alors $k : w$ appartient aux deux ensembles $Premier_k(\alpha\theta)$ et $Premier_k(\beta\theta)$ et donc l'intersection est non vide.
- $: \Rightarrow$ Si la condition de droite n'est pas satisfaite, alors il existe un mot u dans l'intersection et à l'aide de ce mot on obtient L qui n'est pas $LL(k)$. ■

COROLLAIRE 1 Les grammaires $LL(k)$ ne sont pas récursives à gauche.

PREUVE : Supposons que G soit $LL(k)$ pour un certain k et récursive à gauche. Alors $\exists A \rightarrow A\alpha$ et $A \rightarrow \beta$ dans P (on suppose toujours qu'aucun symbole n'est inutile). Alors considérons les deux dérivations $S \vdash_g^* uA\theta \vdash_g^+ uA\alpha^n\theta \vdash uA\alpha^{n+1}\theta$ et $S \vdash_g^* uA\theta \vdash_g^+ uA\alpha^n\theta \vdash u\beta\alpha^n\theta$. Comme G est $LL(k)$, les ensembles $Premier_k(A\alpha^{n+1}\theta)$ et $Premier_k(\beta\alpha^n\theta)$ sont d'intersection nulle. Comme $A \rightarrow \beta \in P$, $Premier_k(\beta\alpha^{n+1}\theta) \subseteq Premier_k(A\alpha^{n+1}\theta)$. Donc :

$$Premier_k(\beta\alpha^{n+1}\theta) \cap Premier_k(\beta\alpha^n\theta) = \emptyset.$$

Mais alors, si $\alpha \vdash \varepsilon$ et on a une contraction avec l'égalité précédente. Sinon, on considère $n > k$ pour avoir encore une contradiction. ■

Et encore une caractérisation, mais cette fois pour $k = 1$:

PROPOSITION 2 Une grammaire est $LL(1)$ ssi pour toutes productions distinctes $A \rightarrow \alpha$ et $A \rightarrow \beta$, on a :

$$Premier_1(\alpha Suivant_1(A)) \cap Premier_1(\beta Suivant_1(A)) = \emptyset.$$

PREUVE : On utilise le fait que :

$$Premier_1(\alpha Suivant_1(A)) = \begin{cases} Premier_1(\alpha) \setminus \{\varepsilon\} \cup Suivant_1(A) & \text{si } \alpha \vdash_g^* \varepsilon \\ Premier_1(\alpha) & \text{sinon.} \end{cases}$$

• \Rightarrow : Soit I l'intersection des deux ensembles. Si I est non vide, alors il existe $a \in I$ et alors :

– Si α et β ne dérivent pas ε , alors a appartient à l'intersection des ensembles $Premier_1(\alpha)$ et $Premier_1(\beta)$. Donc $\alpha \vdash_g^* aw$ et $\beta \vdash_g^* aw'$.

Et on peut exhiber deux dérivations à gauche : $S \vdash_g^* uA\theta \vdash u\alpha\theta \vdash_g^* uawt$

et $S \vdash_g^* uA\theta \vdash u\beta\theta \vdash_g^* uaw't'$ avec $1 : awt = 1 : aw't'$ ce qui est absurde car G est $LL(1)$.

– autres cas similaires.

• \Leftarrow : C'est immédiat en utilisant la définition. ■

On en déduit une autre caractérisation des grammaires $LL(1)$:

PROPOSITION 3 G est $LL(1)$ ssi pour toutes productions distinctes $A \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_m$, on a :

1. Les ensembles $Premier_1(\alpha_i)$ sont deux à deux disjoints,
2. De $\alpha_i \vdash_g^* \varepsilon$ il résulte que $Premier_1(\alpha_j) \cap Suivant_1(\alpha_i)$ pour tout $j \neq i$.

A ce stade, on a tout ce qu'il faut pour montrer que si G est $LL(k)$, alors $L(G)\$$ est reconnu par un automate à pile déterministe par pile vide.

PROPOSITION 4 Soit G une grammaire algébrique $LL(1)$. Alors $L(G)\$,$ où $\$$ est un caractère n'appartenant pas à $(\Sigma \cup N)$, est reconnu par APD par pile vide.

PREUVE : On construit à l'aide de G l'automate

$$\mathcal{M} = (\Sigma \cup \{q_0, \$\}, \Sigma \cup \{\$\}, N, \delta, q_0, S)$$

avec δ définie par :

- $\delta(q_0, \$, \$) = (\$, \varepsilon)$ si $\varepsilon \in L(G)$.
- Pour $a \in \Sigma$, $\delta(q_0, a, S) = (a, \alpha)$ si $S \rightarrow \alpha \in P$ et $a \in Premier_1(Suivant_1(S))$.
- Pour $a \in \Sigma$, $\delta(a, \varepsilon, A) = (a, \alpha)$ si $A \rightarrow \alpha \in P$ et $a \in Premier_1(Suivant_1(A))$.
- Pour $a \in \Sigma$ et $b \in (\Sigma \cup \$)$, $\delta(a, b, a) = (b, \varepsilon)$.

Montrons alors que $L(G)\$ = L_P(G)$. Pour cela, prouvons :

$$A\beta \stackrel{*}{\vdash}_g a_1 \dots a_p \text{ ssi } (a_1, a_2 \dots a_p \$, A\beta) \stackrel{*}{\vdash}_{\mathcal{M}} (\$, \varepsilon, \varepsilon)$$

Chaque implication sera prouvée par récurrence :

$$\bullet \Rightarrow HR_n = \forall k \leq n, A\beta \stackrel{n}{\vdash}_g a_1 \dots a_p \Rightarrow (a_1, a_2 \dots a_p \$, A\beta) \stackrel{*}{\vdash}_{\mathcal{M}} (\$, \varepsilon, \varepsilon) :$$

- si $n = 1$ Supposons donc que $A\beta \stackrel{1}{\vdash}_g a_1 \dots a_p$. Alors il existe $\alpha, A \rightarrow \alpha \in P$ et $A\beta \vdash \alpha\beta = a_1 \dots a_p$. Trois cas sont alors possibles :
 - Si $\alpha = \varepsilon$ et $\beta = a_1 \dots a_p$, alors :

$$(a_1, a_2 \dots a_p \$, A\beta) \stackrel{1}{\vdash}_{\mathcal{M}} (a_1, a_2 \dots a_p \$, \beta) = (a_1, a_2 \dots a_p \$, a_1 \dots a_p) \stackrel{*}{\vdash}_{\mathcal{M}} (\$, \varepsilon, \varepsilon),$$

la deuxième dérivation étant bien définie car $a_1 \in Premier_1(\alpha Suivant_1(A))$.

- Si $\alpha = a_1 \dots a_l$ et $\beta = a_{l+1} \dots a_p$, cela se traite de façon identique.
- Si $\alpha = a_1 \dots a_p$ et $\beta = \varepsilon$, idem.
- soit n quelconque. On va découper la dérivation de taille n dans G en une première dérivation $A\beta \stackrel{1}{\vdash}_G \alpha\beta$ et les $n - 1$ autres : $\alpha\beta \stackrel{n-1}{\vdash}_G a_1 \dots a_p$. On a alors $A \rightarrow \beta \in P$, et en écrivant $\alpha = u\beta\alpha'$, où $u \in \Sigma^*$, ou bien $u = \varepsilon$ et on écrit $A\beta \stackrel{1}{\vdash}_G B\alpha'\beta' \stackrel{n-1}{\vdash}_G$, ou bien $u = a_1 \dots a_l$ et on obtient $B\alpha'\beta \stackrel{m}{\vdash}_G a_{l+1}a_p$ en appliquant le lemme fondamental.

En appliquant l'hypothèse de récurrence sur la dérivation plus petite (taille $n - 1$ ou m), on obtient bien le résultat voulu.

$$\bullet \Leftarrow \text{On va montrer que } \forall n, (a_1, a_2 \dots a_p \$, A\beta) \stackrel{n}{\vdash}_{\mathcal{M}} (\$, \varepsilon, \varepsilon) \Rightarrow A\beta \stackrel{*}{\vdash}_G a_1 \dots a_p.$$

- si $n = 2$ Si on a $(a_1, a_2 \dots a_p \$, A\beta) \stackrel{1}{\vdash}_{\mathcal{M}} (a_1, a_2 \dots a_p \$, \alpha\beta) \stackrel{1}{\vdash}_{\mathcal{M}} (\$, \varepsilon, \varepsilon)$ c'est que $A \rightarrow \alpha \in P$ et $a_1 \in Premier_1(\alpha Suivant_1(A))$. Donc ou bien $\alpha = a_1$ et $\beta = \varepsilon$, ou bien $\alpha = \varepsilon$ et $\beta = a_1$, ce qui entraîne dans chaque cas $A\beta \stackrel{*}{\vdash}_G a_1$.
- soit n quelconque. On découpe là aussi la dérivation en un premier pas, puis les $n - 1$ autres à qui on peu appliquer l'HR. Cela se passe bien. ■

REMARQUE 5 C'est ce dernier automate que l'on a construit en cours de compilation, sauf que les états sont utilisés pour la construction de la table.

3 Grammaires $LR(k)$

EXEMPLE 2 *Considérons la grammaire définie par les productions suivantes :*

$$\begin{cases} S' \rightarrow Sc \\ S \rightarrow A \mid SA \\ A \rightarrow aSb \mid ab \end{cases}$$

DÉFINITION 5 (FSD)

On appellera **forme syntaxique droite** tout mot $\gamma \in (\Sigma \cup N)^*$ qui se dérive le plus à droite à partir de S . Dans l'exemple précédent, $Saabbc$ est une FSD.

3.1 Notion de manche

DÉFINITION 6

Soit γ une FSD. Un couple $(A \rightarrow \beta, i)$ où $A \rightarrow \beta \in P$ et $i \geq 0$ est dite une **poignée** pour γ si $S \xrightarrow{*}_d \alpha Aw \vdash \alpha\beta w$ avec $\alpha\beta w = \gamma$ et $i = |\alpha\beta|$.

EXEMPLE 3

- Soit G définie par les productions suivantes :

$$\begin{cases} S \rightarrow aB \mid ab \\ B \rightarrow b \end{cases}$$

Alors pour la FSD ab , $(S \rightarrow ab, 2)$ et $(B \rightarrow b, 2)$ sont des poignées. En effet, on a $S \vdash ab$ et $S \vdash aB \vdash ab$.

- Soit G' définie par les productions suivantes :

$$\begin{cases} S \rightarrow aA \mid Aa \\ A \rightarrow a \end{cases}$$

Alors $(A \rightarrow a, 1)$ et $(A \rightarrow a, 2)$ sont des poignées pour $\gamma = aa$.

3.2 Définition de $LR(k)$

DÉFINITION 7

Soit G une grammaire algébrique réduite (*i.e.* sans symbole inutile) telle que S ne dérive pas S . Alors G est $LR(k)$ pour $k \geq 0$ si la condition suivante est vérifiée :

$$\begin{cases} (1) & S \xrightarrow{*}_d \alpha Aw \vdash \alpha\beta w \\ (2) & S \xrightarrow{*}_d \alpha' A' w' \vdash \alpha' \beta' w' = \alpha\beta w'' \Rightarrow (A \rightarrow \beta, |\alpha\beta|) = (A' \rightarrow \beta', |\alpha' \beta'|), \\ (3) & k : w = k : w' \end{cases}$$

c'est-à-dire $A = A'$, $B = B'$, $|\alpha\beta| = |\alpha' \beta'|$, donc $w' = w''$ et $\alpha' = \alpha$, $\beta' = \beta$.

EXEMPLE 4

- Soit G définie par les productions suivantes :

$$\begin{cases} S \rightarrow aAc \\ A \rightarrow Abb \mid b \end{cases}$$

est $LR(0)$. En effet, les formes syntaxiques droites que l'on peut obtenir sont :

- aAc de poignée ($S \rightarrow aAc, 3$)
 - $aAb^{2n}c$ de poignée ($A \rightarrow Abb, 4$)
 - $ab^{2n+1}c$ de poignée ($A \rightarrow b, 2$).
- Attention, soit G' définie par les productions suivantes :

$$\begin{cases} S \rightarrow aB \mid ab \\ A \rightarrow a \end{cases}$$

Alors cette grammaire engendre le même langage que G mais elle n'est pas $LR(0)$. Il faut considérer $S \xrightarrow{\frac{1}{d}} aAc \xrightarrow{\frac{1}{d}} abc$ et $S \vdash aAc \vdash abAbc \vdash abbbc$, on obtient les manches pour $ab : (A \rightarrow b, 2)$ et $(A \rightarrow b, 3)$.

3.3 Non-ambiguïté de $LR(k)$

LEMME 1 Soit G une grammaire algébrique réduite. Supposons que l'on ait les dérivations : $S \xrightarrow{\frac{*}{d}} \alpha Aw \vdash \alpha\beta w$ et $S \xrightarrow{\frac{*}{d}} \alpha' A' w' \vdash \alpha' \beta' w' = \alpha\beta w$. Alors on a l'équivalence :

$$\alpha Aw = \alpha' A' w' \text{ ssi } (A \rightarrow \beta, |\alpha\beta|) = (A' \rightarrow \beta', |\alpha'\beta'|)$$

PREUVE : Facile et laissée au lecteur. ■

LEMME 2 Soit G une grammaire algébrique réduite. Alors G est non ambiguë si et seulement si toute forme algébrique droite a exactement une poignée à l'exception de S qui n'en a aucune.

PREUVE :

- \Rightarrow : Supposons G non ambiguë :
 - S n'a pas de poignée. Sinon, il existerait une poignée $(A \rightarrow \beta, i)$ telle que $S \xrightarrow{\frac{*}{d}} \alpha Aw \vdash \alpha\beta w = S, i = |\alpha\beta|$ donc pour tout u mot sur Σ^* , on aurait : $S \xrightarrow{\frac{+}{d}} S \xrightarrow{\frac{*}{d}} u$ et $S \vdash u$, ce qui contredit l'hypothèse.
 - Toute forme syntaxique droite différente de S possède une poignée puisque G est réduite.
 - Montrons qu'il n'y en a qu'une par FSD. Supposons que $(A \rightarrow \beta, i)$ et $(A' \rightarrow \beta', i')$ soient des poignées pour γ une FSD. En appliquant la définition des poignées, on obtient l'existence des dérivations :

$$S \vdash \alpha Aw \vdash \alpha\beta w \xrightarrow{\frac{*}{d}} u \text{ et } S \vdash \alpha' A' w' \vdash \alpha' \beta' w' = \gamma = \alpha\beta w \xrightarrow{\frac{*}{d}} u$$

, ce qui contredit le fait que G est supposée non ambiguë.

- \Leftarrow : Réciproquement, montrons que G n'est pas ambiguë. Supposons le contraire. Alors il existe un mot u qui admet deux dérivations droites distinctes :

$$\alpha_0 = S \vdash \alpha_1 \vdash \dots \vdash \alpha_m = u \text{ et } \alpha'_0 = S \vdash \alpha'_1 \vdash \dots \vdash \alpha_{m'} = u$$

Alors il existe certainement i , $\alpha_{m-i} \neq \alpha'_{m'-i}$ (distinguer les cas $m = m'$ et $m \neq m'$). Soit alors j le plus petit entier vérifiant $\alpha_{m-j} \neq \alpha'_{m'-j}$. Alors on obtient $\alpha_{m-j+1} = \alpha'_{m'-j+1}$. Comme toute forme syntaxique a exactement une poignée, on déduit que $\alpha_{m-j} = \alpha_{m'_j}$. Ce qui est contradictoire avec j minimal. ■

On en déduit immédiatement le corollaire à l'aide du lemme précédent :

COROLLAIRE 2 *Si G est une grammaire $LL(k)$, alors elle n'est pas ambiguë.*

3.4 L'automate caractéristique d'une grammaire algébrique

DÉFINITION 8

On appelle **préfixe viable** de G tout mot $\mu \in (\Sigma \cup N)^*$ tel que

$$S \xrightarrow[d]{*} \alpha A w \vdash \alpha \beta w, \text{ et } \mu \text{ préfixe de } \alpha \beta.$$

DÉFINITION 9

On appelle **item** de G tout objet $[A \rightarrow \beta_1 \bullet \beta_2]$ tel que $A \rightarrow \beta_1 \beta_2 \in P$.

DÉFINITION 10

On appelle **item complet** un item $[A \rightarrow \bullet]$ ou $[A \rightarrow \beta \bullet]$.

DÉFINITION 11

Un item $[A \rightarrow \beta_1 \bullet \beta_2]$ est **valide** pour un préfixe viable μ de la grammaire si il existe une dérivation de la forme :

$$S \xrightarrow[d]{*} \alpha A w \vdash \alpha \beta_1 \beta_2 w,$$

telle que $\mu = \alpha \beta_1$.

On a alors la proposition suivante :

PROPOSITION 5 *Pour tout préfixe viable μ , il existe un item valide pour μ .*

PREUVE : facile mais à faire! ■

DÉFINITION 12 (AUTOMATE CARACTÉRISTIQUE)

L'automate caractéristique \mathcal{C}_G d'une grammaire G a pour états les items de G (Q_C), son alphabet est $\Sigma \cup N$. Son état initial est $[S' \rightarrow \bullet S] = q_{0_C}$ et les états d'acceptation sont $F_C\{[A \rightarrow B \bullet] \mid A \rightarrow B \in P\}$. Enfin, la fonction de transition δ_C est donnée par :

$$- \delta([A \rightarrow \alpha \bullet X \beta], X) = \{[A \rightarrow \alpha X \bullet \beta]\} \text{ quand } A \rightarrow \alpha X \beta \text{ avec } X \in \Sigma \cup N.$$

– $\delta([A \rightarrow \alpha \bullet B\beta], \varepsilon) = \{[B \rightarrow \bullet u], B \rightarrow u \in P\}$ pour $B \in N$.

PROPOSITION 6 *Soient $u \in (\sigma \cup N)^*$ et $q \in Q_C$. Alors $q \in \delta_C(q_{0c}, u)$ ssi μ est un préfixe viable de G et q est un item valide pour μ .*

PREUVE :

- \Rightarrow . Supposons que $q \in \delta_C(q_{0c}, \mu)$. Il existe donc un chemin de longueur n menant de q_{0c} à q dans l'automate. On va montrer par récurrence sur n la longueur du chemin la proposition.
 - si $n = 1$ Alors $q_{0c} = [S' \rightarrow \bullet S] \rightarrow_\mu [S \rightarrow \bullet \gamma]$ et nécessairement $\mu = \varepsilon$ et $S \rightarrow \gamma \in P$. Alors $S \stackrel{\frac{1}{c}}{\vdash} \gamma$ et $[S \rightarrow \bullet \gamma]$ est valide pour ε .
 - On suppose que c'est vrai pour les chemins de longueur inférieur strict à n . On va montrer que c'est vrai pour n . Si on prend un chemin de longueur n , il se segmente en un chemin de longueur $n - 1$ et se termine sur une transition sur ε ou une transition à l'aide d'un élément de $\Sigma \cup N$:
 - Si le chemin est de la forme $q_{0c} \rightarrow_\mu q' \rightarrow_\varepsilon q$, alors par HR, q' est un item valide pour μ . On note $q' = [A \rightarrow \beta_1 \bullet \beta_2]$ et on a alors $S \stackrel{*}{\vdash}_d \alpha Aw \vdash \alpha \beta_1 \beta_2 w$ avec $\mu = \alpha \beta_1$. Comme dans l'automate la transition (q, q') est étiquetée par ε , on a appliqué la seconde règle de la définition pour construire cette transition. Par conséquent, β_2 commence par une variable B et donc s'écrit $\beta_2 = B\beta'_2$ et aussi on a $q = [B \rightarrow \bullet \gamma]$. Alors les dérivations $S \stackrel{*}{\vdash}_d \alpha Aw \vdash \alpha \beta_1 B\beta'_2 \vdash \alpha \beta_1 \gamma \beta'_2 w$ prouvent que q est valide pour μ .
 - si $n = 0$: $|\mu| = 0$ signifie $\mu = \varepsilon$, et $q = [A \rightarrow \beta_1 \bullet \beta_2]$ est un item valide pour ε , ce qui signifie qu'il existe une dérivation la plus à droite du type : $S \stackrel{*}{\vdash}_d \alpha Aw \vdash \alpha \beta_1 \beta_2 w$ tel que $\alpha \beta_1 = \varepsilon = \alpha = \beta_1$. Alors en réécrivant cette dernière dérivation : $S \stackrel{*}{\vdash}_d Aw$ et $A \rightarrow \beta_2 \in P$. Cela implique que $S \rightarrow X\alpha_1 w \stackrel{*}{\vdash}_d Xw' \vdash A\beta'w'$ (X dernière variable avant A). D'où $S \rightarrow X\alpha_1 w_1 \in P$ et $X \rightarrow a\beta' \in P$. Alors dans l'automate $[S' \rightarrow S] \rightarrow_\varepsilon [S \rightarrow \bullet X\alpha_1 w_1] \rightarrow_\varepsilon [X \rightarrow \bullet A\beta'] \rightarrow_\varepsilon [A \rightarrow \bullet \beta_2]$, donc $q_{0c} \rightarrow_\varepsilon q$ et c'est gagné.
 - On suppose que c'est vrai pour les mots de longueur inférieur strict à n . On va montrer que c'est vrai pour n . Si μ est un préfixe viable et $q = [A \rightarrow \beta_1 \bullet \beta_2]$ est un préfixe viable pour μ , alors par définition on a la dérivation : $S \stackrel{*}{\vdash}_d \alpha Aw \vdash \alpha \beta_1 \beta_2 w$ et $\mu = \alpha \beta_1$. On écrit alors $\mu = \mu'X$ avec $|\mu'| = |\mu| - 1 = n - 1$.
 - Si $\beta_1 \neq \varepsilon$, alors $\beta_1 = \beta'_1 X$ et par HR $[A \rightarrow \beta'_1 \bullet X\beta_2]$ est un item valide pour μ' . donc on a :

$$q_{0c} \rightarrow_{\mu'} [A \rightarrow \beta'_1 \bullet X\beta_2] \rightarrow_X [A \rightarrow \beta'_1 X \bullet \beta_2] = [A \rightarrow \beta_1 \bullet \beta_2]$$

et c'est bien ce qu'on veut.

- Si $\beta_1 = \varepsilon$, alors $q = [A \rightarrow \bullet \beta_2]$, $\alpha = \mu'X$, $S \stackrel{*}{\vdash}_d \alpha Aw \stackrel{\alpha}{\vdash}_\beta w =$

$\mu'X\beta_2w$. Donc cela s'écrit encore :

$$S \xrightarrow{*}_d \theta' Bw' \longmapsto \theta\nu X\rho w' \xrightarrow{*}_d \theta\nu XAw \longmapsto \theta\nu X\beta_2w = \mu'X\beta_2w$$

Alors ρ s'écrit forcément $C\rho'$ donc $\rho w' = C\rho'w' \xrightarrow{*}_d A\nu'w'$, avec $B \rightarrow \nu X\rho \in P$. Alors $[B \rightarrow \nu \bullet X\rho]$ est valide pour $\theta\nu = \mu'$:

$$q_{0c} \rightarrow_{\mu'} [B \rightarrow \nu \bullet X\rho] \rightarrow_{\alpha} [B \rightarrow \nu X \bullet \rho] \rightarrow_{\varepsilon} [C \rightarrow \bullet A\nu'] \rightarrow_{\varepsilon} [A \rightarrow \bullet \beta_2]$$

■

On détermine ensuite l'automate \mathcal{C}_G en \mathcal{D}_G . Alors on obtient une caractérisation des grammaires algébriques $LR(0)$:

PROPOSITION 7 *Une grammaire algébrique réduite (i.e. sans caractères inutiles) est $LR(0)$ ssi :*

1. *S ne dérive pas S à droite,*
2. *\mathcal{D}_G ne contient pas d'état impropre (i.e. il ne contient pas plusieurs items complets distincts ni d'item complet accompagné d'items incomplets)*

PREUVE : La preuve, similaire à la précédente, est laissée au lecteur. ■

3.5 Automate reconnaisseur de $LR(0)$

On va, dans cette section, décrire un automate à pile reconnaissant le langage engendré par une grammaire algébrique $LR(0)$.


Sa fonction de transition sera notée $\tau : Q \times \gamma \times \Sigma \cup \{\varepsilon\} \rightarrow Q \times \Gamma^+$. De plus, dans le mot de pile, la lettre la plus à droite sera ici le sommet de pile. L'alphabet de pile est $Q_{\mathcal{D}} \cup N \cup \Sigma$, où $Q_{\mathcal{D}} = \{e_0, e_1, \dots, e_k\}$ sont les états de l'automate déterminisé précédent (e_0 était l'état initial). e_0 sera le symbole de fin de pile. L'état initial de cet automate à pile sera q_0 . Construisons maintenant la fonction de transition :

- $\tau(q_0, e_0, a) = (q_0, e_0 a \delta_{\mathcal{D}}(e_0, a))$.
- $\tau(q_0, e, a) = (q_0, e, a) = (q_0, e_0 a \delta_{\mathcal{D}}(e_0, a))$ si e ne contient pas d'item complet, et $a \in \Sigma$.
- Si e contient un item complet $[A \rightarrow \beta_1 \dots \beta_n \bullet]$, chaque $\beta_i \in \Sigma \cup N$, le mot de sommet de pile est alors de la forme $e' \beta_1 e_1 \beta_2 e_2 \dots \beta_n e_n$. Alors on va le manger, d'où les règles suivantes :
 - $\tau(q_0, e_n, \varepsilon) = (q_1, \varepsilon)$ (changement d'état "dépile")
 - $\tau(q_1, \beta_n, \varepsilon) = (q_2, \varepsilon)$
 - ...
 - $\tau(q_1, \beta_1, \varepsilon) = (q_{2n}, \varepsilon)$
 - $\tau(q_{2n}, e', \varepsilon) = \begin{cases} (q_0, e' A \delta_{\mathcal{D}}(e', A)) & \text{si } A \neq S' \\ (q_0, e' S') & \text{si } A = S' \end{cases}$
 - $\tau(q_0, S', \varepsilon) = (q^*, \varepsilon)$ (c'est fini)
 - $\tau(q^*, e_0, \varepsilon) = (q^*, \varepsilon)$.

EXEMPLE 5 Pour la grammaire :

$$G = \begin{cases} S' \rightarrow Sc \\ S \rightarrow A \mid SA \\ A \rightarrow aSb \mid ab \end{cases},$$

on a obtenu l'automate suivant :



En notant les états :

- $e_0 = \{S' \rightarrow \bullet Sc, S \rightarrow \bullet SA, S \rightarrow \bullet A, A \rightarrow \bullet aSb, A \rightarrow \bullet ab\}$
- $e_1 = \{S' \rightarrow S \bullet c, S \rightarrow S \bullet A, A \rightarrow \bullet aSb, A \rightarrow \bullet ab\}$
- $e_2 = \{S \rightarrow A \bullet\}$
- $e_3 = \{A \rightarrow a \bullet Sb, A \rightarrow a \bullet b, A \rightarrow \bullet aSb, S \rightarrow \bullet A, S \rightarrow \bullet SA, A \rightarrow \bullet ab\}$
- $e_4 = \{S' \rightarrow Sc \bullet\}$
- $e_5 = \{S \rightarrow SA \bullet\}$
- $e_6 = \{S \rightarrow S \bullet A, A \rightarrow aS \bullet b, A \rightarrow \bullet ab, A \rightarrow \bullet aSb\}$
- $e_7 = \{A \rightarrow ab \bullet\}$
- $e_8 = \{A \rightarrow aSb \bullet\}$

Alors pour le mot $abaabc$, on a les mots de pile successifs : $e_0ae_3be_7$, puis comme e_7 contient un item "Reduce" on obtient e_0Ae_2 , puis $e_0Se_1ae_3a_3ba_7$, etc.

3.6 Grammaires et langages $LR(1)$

On admettra ici que tout langage $LR(1)$ est algébrique déterministe.

THÉORÈME 1 *Tout langage algébrique déterministe est engendré par une grammaire $LR(1)$.*

Le cheminement de la preuve est le suivant :

- Soit L un langage algébrique déterministe. Alors il est reconnu par un APD par état final. Alors $L\$$ est reconnu par un APD par pile vide. $L\$$ a aussi la propriété du préfixe.
- Notion de grammaire algébrique stricte :

DÉFINITION 13

Une grammaire algébrique est dite déterministe **stricte** si il existe une partition Π de $N \cup \Sigma$ telle que :

1. $\Sigma \in \Pi$
2. pour tous A, A' de N , pour tous $\alpha, \beta, \beta' \in (\Sigma \cup N)^*$, si $A \rightarrow \alpha\beta \in P$, $\alpha \rightarrow \alpha\beta' \in P$ et $A \equiv A'[\Pi]$, alors
 - ou bien β et β' sont distincts de ε et $1 : \beta \equiv 1 : \beta'[\Pi]$
 - ou bien $\beta = \beta' = \varepsilon$ et $A = A'$.

- On montre le théorème suivant :

THÉORÈME 2 *La famille des langages algébriques ayant la propriété su préfixe est celle des langages engendrés par les grammaires algébriques déterministes strictes.*

- Avec la définition suivante :
- Il existe un algorithme qui décide si une grammaire algébrique donnée est déterministe stricte ou non.
- Toute grammaire algébrique stricte est $LR(0)$. Donc $L\$$ est engendré par une grammaire $LR(0)$, et qui plus est par une grammaire $LR(0)$ sans ε -transition.
- On utilise enfin(!) le lemme :

LEMME 3 *Soit G une grammaire $LR(0)$ de la forme $(N \cup \{\$, \Sigma \cup \{\$, P, S)$ où $P \subseteq N \times ((N \cup \Sigma)^* \times (n \cup \Sigma)^*\$)$ et $L(G) \subseteq \Sigma^*\$$ et telle qu'il n'existe pas de dérivation pouvant mener de S à $S\$$ dans G . Alors la grammaire $G' = (N, \Sigma, P', S)$ avec $P' = P_1 \cup P_2$, $P_1 = \{A \rightarrow \beta \mid A \rightarrow \beta \in P, \beta \in (N \cup \Sigma)^*\}$ et $P_2 = \{A \rightarrow \beta \mid A \rightarrow \beta\$ \in P\}$ est $LR(1)$ et $L(G')\$ = L(G)$.*

THÉORÈME 3 *Tout langage engendré par une grammaire $LR(k)$ est algébrique déterministe.*

On va maintenant construire un analyseur $LR(k)$, c'est-à-dire un automate déterministe pour une grammaire $LR(k)$.

3.7 Analyseur $LR(k)$

DÉFINITION 14 ($LR(k)$ -ITEM)

Un $LR(k)$ -item pour une grammaire algébrique est $[A \rightarrow \beta_1 \bullet \beta_2, u]$, où $u \in \text{Suivant}_k(A)$ et $A \rightarrow \beta_1\beta_2 \in P$.

REMARQUE 6 En cours de compilation, on a noté cela $[A \rightarrow \beta_1 \bullet \beta_2]\{u\}$.

DÉFINITION 15

L'item $[A \rightarrow \beta_1 \bullet \beta_2, u]$ est dit **valide** pour un préfixe viable μ si

$$S \xrightarrow[d]{*} \alpha A w \vdash \alpha \beta_1 \beta_2 w \text{ avec } \mu = \alpha \beta_1 \text{ et } u = k : w$$

Il existe un algorithme qui permet de calculer les ensembles d'items valides pour les préfixes viables de la grammaire.

On note \mathcal{S}_G l'ensembles des ensembles de $LR(k)$ -items valides pour les préfixes viables de G .

DÉFINITION 16

Un ensemble \mathcal{S} d'ensembles de $LR(k)$ -items valides est dit **consistant** si pour tout ensemble I de \mathcal{S} , $\forall A, A' \in N, \forall \beta, \beta_1, \beta_2 \in (\Sigma \cup N)^*$ vérifiant $1 : \beta_2 \notin N$ et pour u, v mots de Σ^* de taille $\leq k$, $u \in Premier_k(\beta_2 v)$, on a :

$$\left([A \rightarrow \beta \bullet, u] \in I, [A \rightarrow \beta_1 \bullet \beta_2] \in P \right) \Rightarrow \left([A \rightarrow \beta \bullet, u] = [A' \rightarrow \beta_1 \bullet \beta_2, v] \right)$$

On a alors :

THÉORÈME 4 G est $LR(k)$ ssi $\mathcal{S}_{k,G}$ est consistant.

Tous ces résultats nous permettent de construire l'analyseur $LR(k)$ cherché :

On commence par définir deux "fonctions" f et g dites d'action et de succession. Soit T un ensemble de $LR(k)$ -items de G et $u \in \Sigma^{\leq k}$. On définit :

1. $f(T, u)$: **décaler** si il existe $\beta_1 \in (N \cup \Sigma)^*$, $\beta_2 \in \Sigma(N \cup \Sigma)^*$, $v \in \Sigma^{\leq k}$ et $A \in N$ vérifiant :

$$[A \rightarrow \beta_1 \bullet \beta_2] \in T \text{ avec } u \in Premier_k(\beta_2 v)$$

2. $f(T, u)$: **réduire** la production $A \rightarrow \beta$ si $[A \rightarrow \beta \bullet, u] \in T$.
3. $f(T, u)$: **erreur** partout ailleurs
4. si on note $T = V_k(\gamma)$ (i.e. γ préfixe viable et $V_k(\gamma)$ valide pour γ) et $X \in (N \cup \Sigma)$:
 - $g(V_k(\gamma), X) = V_k(\gamma X)$ si $V_k(\gamma) \neq \emptyset$
 - $g(V_k(\gamma), X)$: **erreur** sinon.

PROPOSITION 8 Si l'ensemble d'ensemble d'items T est consistant, alors f et g sont vraiment des fonctions.

On numérote les productions de la grammaire. Soit $(\gamma T, z, \rho)$ une configuration, où γT désigne le contenu de la pile (T est au dessus), z l'entrée, ρ la sortie. Quelle est la configuration suivante ?

1. Si $f(T, k : z)$ =décaler alors
 - si $z = \varepsilon$ retourner ERREUR
 - si $z \neq \varepsilon$, notons $z = bz', b \in \Sigma$:
 - si $g(T, b)$ =erreur alors retourner ERREUR
 - sinon $(\gamma, T, bz', \rho) \mapsto (\gamma T b g(T), z', \rho)$
2. Si $f(T, k : z)$ =réduire(i) alors on veut dépiler $2|\beta|$ symboles si la production numéro i est $A \rightarrow \beta$. Donc si $\gamma T = \gamma T \gamma''$ avec $|\gamma''| = 2|\beta|$, on a deux cas :
 - si $T' = T_0$ (fonds de pile), $S = A, z = \varepsilon$, alors $(\gamma T, z, rho) \mapsto (T_0, \varepsilon, \rho i)$ ACCEPTÉ
 - si $T \neq T_0$ alors :
 - si $g(T', A)$ =erreur alors retourner ERREUR
 - sinon la nouvelle configuration est $(\gamma T' A g(T', A), z, \rho i)$.
3. si $f(T, k : z)$ =erreur alors retourner ERREUR