

# Preuve d'un algorithme de calcul d'une table de parsing $LL(1)$

Thibaut ANTOINE (thibaut.antoine@ens-rennes.fr)

## Phrase d'introduction

L'analyse syntaxique  $LL(1)$  utilise une *table de parsing* pour calculer un AST d'une expression selon une grammaire passée en entrée. On illustre une manière de calculer la table et une preuve de sa correction.

## 1 Passage en « forme $LL(1)$ »

[TIG]

Grammaire pour des sommes :

—  $S \rightarrow E\$$

—  $E \rightarrow E + E \mid (E) \mid \text{num}$

*Exemple* :  $w = 1 + 2 + 3\$$

On présente une grammaire simple pour des sommes qui n'est pas  $LL(1)$ . En particulier, la règle  $E \rightarrow E + E$  présente de la récursivité à gauche et par exemple, on ne peut pas parser le mot  $w = 1 + 2 + 3\$$  car on ne peut pas savoir à l'avance combien de fois appliquer la règle.

$\rightsquigarrow$  Grammaire  $LL(1)$  équivalente :

—  $S \rightarrow E\$$

—  $E \rightarrow FE' ; E' \rightarrow +FE' \mid \varepsilon$

—  $F \rightarrow \text{num} \mid (E)$

*Attention* : pas utilisé en pratique (parsing  $LR$ ).

On peut éliminer la récursivité à gauche de cette grammaire avec l'ajout de variables et de règles. Cependant la transformation est assez lourde, et en pratique il existe d'autres techniques de parsing (comme l'analyse syntaxique  $LR(k)$ ) qui permettent de l'éviter.

## 2 Calcul de nullable, first et follow

[SCH]

On va ici énoncer la caractérisation des ensembles/valeurs  $\text{nullable}(X)$ ,  $\text{first}(X)$  et  $\text{follow}(X)$  pour une variable  $X$  par leurs équations de point fixe, qui permettent d'obtenir des algorithmes de calcul. On ne rappelle pas ici leurs définitions, il faut se référer au plan.

**Théorème.** Pour  $X \in V$ ,  $X \rightarrow Y_1 \cdots Y_p$ ,

1.  $\text{nullable}(\varepsilon)$ , et  $[\forall i, \text{nullable}(Y_i)] \Rightarrow \text{nullable}(X)$ ,
2.  $\text{first}(X)$  est le pp. ens. tel que

$$\begin{cases} \forall t \in T, \text{first}(t) = \{t\} \\ \forall i, \text{nullable}(Y_1 \cdots Y_{i-1}) \Rightarrow \text{first}(Y_i) \subseteq \text{first}(X) \end{cases}$$

3.  $\forall i, j$  :

$$\begin{cases} \text{nullable}(Y_{i+1} \cdots Y_p) \Rightarrow \text{follow}(X) \subseteq \text{follow}(Y_i) \\ \text{nullable}(Y_{i+1} \cdots Y_{j-1}) \Rightarrow \text{first}(Y_j) \subseteq \text{follow}(Y_i) \end{cases}$$

On comprend assez bien ces équations intuitivement :

1. Si toutes les variables d'une règle se dérivent vers  $\varepsilon$  alors la concaténation de ces variables se dérive aussi vers  $\varepsilon$  par le lemme fondamental,
2. La seule lettre qui peut commencer un lexème est le lexème lui-même, et si dans la règle  $X \rightarrow Y_1 \cdots Y_p$  les  $Y_1, \dots, Y_{i-1}$  se dérivent vers  $\varepsilon$  alors les premiers lexèmes de  $Y_i$  peuvent commencer des mots dérivés de  $X$ ,
3. On comprend de manière similaire les équations pour  $\text{follow}$ .

Ces équations donnent un algorithme de calcul. On en donne un exemple d'utilisation sur la grammaire précédente avant de faire la preuve.

**Exemple.**

	<b>nullable</b>	<b>first</b>	<b>follow</b>
$S$	non	num, (	
$E$	non	num, (    ), \$	
$E'$	oui	+	), \$
$F$	non	num, (    ), \$, +	

On commence par le calcul de la colonne  $\text{nullable}$  en parcourant les règles de la grammaire une par une et en appliquant l'équation 1. On calcule ensuite la colonne  $\text{first}$  en ajoutant, pour chaque règle  $X \rightarrow Y_1 \cdots Y_p$ , les éléments de  $\text{first}(Y_i)$  à  $\text{first}(X)$  si  $Y_1 \cdots Y_{i-1}$  est  $\text{nullable}$  (de sorte à ce que l'équation 2 soit toujours vérifiée). On fait enfin la même chose avec la colonne  $\text{follow}$ .

On remarque qu'on peut calculer aussi  $\text{first}(\alpha)$  pour un mot en faisant l'union des  $\text{first}$  de chaque lettre succédant à un préfixe nullable de  $\alpha$ .

On fait la preuve du théorème (seulement pour  $\text{first}$ , la preuve de nullable est similaire mais plus technique).

*Preuve du théorème pour first.* Soit, pour  $X \in V \sqcup T$ ,  $\mu(X)$  le pp. ens. décrit dans l'énoncé.

$\supseteq \forall X, \mu(X) \subseteq \text{first}(X)$  car  $\mu(X)$  le plus petit.

$\subseteq$  Montrons par récurrence forte sur  $n \in \mathbb{N}$  la propriété :

$$\mathcal{P}(n) : \text{"}\forall X, \text{ si } \exists \beta, X \rightarrow^n t\beta \text{ alors } t \in \mu(X)\text{"}$$

• Si  $n = 0$  et  $X \rightarrow^n t\beta$  alors  $X = t$  et  $\mu(X) = \{t\} \ni t$  d'où  $\mathcal{P}(0)$ .

• Si  $n \geq 0$  supposons  $\mathcal{P}(k)$  pour  $0 \leq k \leq n$ .

Si  $X \rightarrow^{n+1} t\beta$  alors  $X \rightarrow Y_1 \cdots Y_p \rightarrow^n t\beta$ . Par le *lemme fondamental* on a  $Y_i \rightarrow^{k_i} u_i$ ,  $\sum_i k_i = n$  et  $u_1 \cdots u_p = t\beta$ .

Soit  $j$  le plus petit indice tel que  $u_j \neq \varepsilon$ . Alors il existe  $\gamma$  tel que  $u_j = t\gamma$  donc par  $\mathcal{P}(k_j)$ ,  $t \in \mu(Y_j)$ .

Or  $u_1 \cdots u_{j-1} = \varepsilon$  donc  $Y_1 \cdots Y_{j-1} \rightarrow^* \varepsilon$  i.e. nullable( $Y_1 \cdots Y_{j-1}$ ). Par hypothèse,  $\mu(Y_j) \subseteq \mu(X)$  et donc  $t \in \mu(X)$ . D'où  $\mathcal{P}(n+1)$ . □

Clarifications sur la preuve :

$\supseteq$  On ne le montre pas, mais on voit que  $\text{first}(X)$  vérifie bien les équations du théorème. Par minimalité de  $\mu(X)$  parmi les ensembles vérifiant ces équations, on déduit l'inclusion.

$\subseteq$  Pour comprendre ce qui nous pousse à prouver cette propriété, il faut revenir à la définition de  $\text{first}$  :

$$\text{first}(X) = \{t \in T \mid \exists \beta \in (T \sqcup V)^*, X \rightarrow^* t\beta\}.$$

On voit alors que si  $\mathcal{P}(n)$  est vraie pour tout  $n$ , alors on a bien  $\text{first}(X) \subseteq \mu(X)$  pour tout  $X$ . En effet, si  $t \in \text{first}(X)$  alors par définition il existe  $n$  et  $\beta$  tels que  $X \rightarrow^n t\beta$ . Alors par  $\mathcal{P}(n)$  on conclut  $t \in \mu(X)$ .

Le reste de la preuve est plutôt clair, il faut faire attention cependant à bien quantifier universellement  $X$  (sur  $T \sqcup V$ ) dans  $\mathcal{P}$ , car dans le cas contraire on ne peut pas utiliser la propriété de récurrence sur  $Y_j$ .

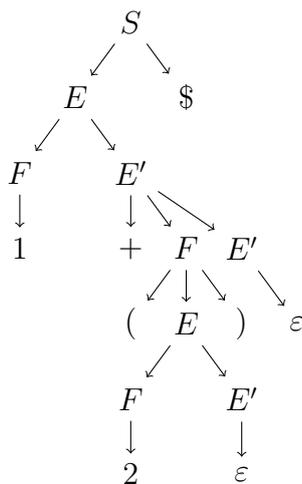
### 3 Table de prédiction

Grâce au calcul de nullable, first, et follow, on peut construire la table de prédiction  $LL(1)$ . On se réfère au plan pour savoir quand ajouter une règle  $X \rightarrow \gamma$  dans la case  $(X, t)$ .

	num	(	)	+	\$
$S$	$S \rightarrow E\$$	$S \rightarrow E\$$			
$E$	$E \rightarrow FE'$	$E \rightarrow FE'$			
$E'$			$E' \rightarrow \epsilon$	$E' \rightarrow +FE'$	$E' \rightarrow \epsilon$
$F$	$F \rightarrow \text{num}$	$F \rightarrow (E)$			

**Utilisation.** On construit l'AST en parcourant simultanément les lettres du mot et les non-terminaux de la frontière, et en appliquant la règle associée dans la table.

**Exemple.** Pour le mot  $w = 1 + (2)\$$  :



On commence par  $S$  et la première lettre de  $w$  est 1, donc on applique la règle  $S \rightarrow E\$$ . On n'a toujours pas consommé la lettre 1, donc on recommence et on applique  $E \rightarrow FE'$ , puis  $F \rightarrow 1$ . On essaye ensuite de consommer + et on applique  $E' \rightarrow +FE'$ , etc.

### Organisation du tableau

<b>Titre</b>	2. Calcul	<i>Preuve</i>	3. Table
1. Forme $LL(1)$ <i>1ère grammaire</i>	<i>Théorème</i>		<i>Table</i>
$\rightsquigarrow$ <i>2ème gram.</i>	<i>Exemple</i>		<i>Utilisation</i>

## Remarques

- Dans tout le développement je n'ai pas fait la différence entre les règles de la grammaire et la relation de dérivation, en écrivant toutes les flèches «  $\rightarrow$  ». Il faut être prêt à savoir les distinguer en cas de question.
- La mention de  $LR(k)$  peut donner lieu à des questions : il peut être intéressant de jeter un œil à la partie en question de [SCH].
- Quelques éléments de preuve de la première inclusion dans le théorème :
  - Si  $t \in T$ ,  $\text{first}(t) = \{u \mid \exists \beta, t \rightarrow^* u\beta\} = \{t\}$  car il est naturel de supposer qu'aucun terminal n'est préfixe d'un autre.
  - Si on a  $X \rightarrow Y_1 \cdots Y_p$  une règle de la grammaire et  $\text{nullable}(Y_1 \cdots Y_{i-1})$  pour un certain  $i$ , alors si  $t \in \text{first}(Y_i)$  on a un  $\beta$  tel que  $Y_i \rightarrow^* t\beta$ . Ainsi on a :

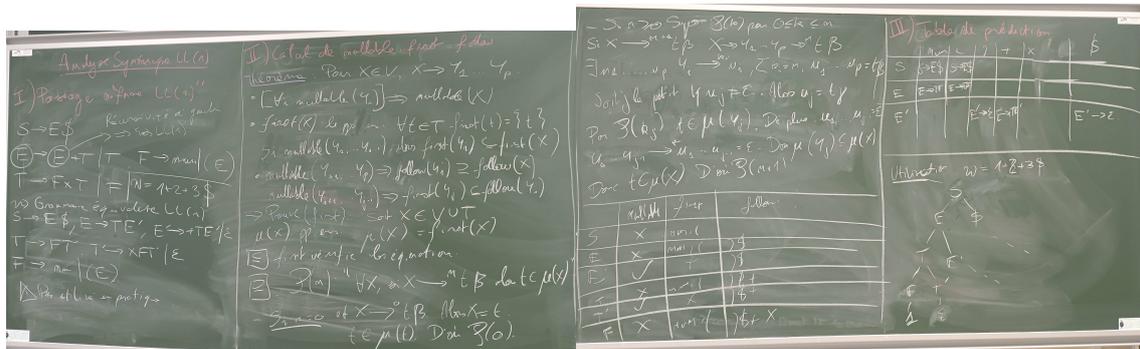
$$\begin{aligned}
X &\rightarrow Y_1 \cdots Y_{i-1} Y_i \cdots Y_p \\
&\rightarrow^* \varepsilon Y_i \cdots Y_p && \text{(car nullable}(Y_1 \cdots Y_{i-1}\text{))} \\
&\rightarrow^* t \underbrace{\beta Y_{i+1} \cdots Y_p}_{=\beta'} \rightarrow^* t\beta' && \text{(par hypothèse sur } t\text{)}
\end{aligned}$$

d'où l'inclusion.

- Ce développement est assez long, il faut être efficace tout au long, quitte à ne pas finir l'exemple de la fin ou la table, et éventuellement diminuer la grammaire en exemple (en supprimant les parenthèses). Il faut être prêt(e) à terminer la table si le jury le demande, cependant.
- La grammaire est en partie tirée de [TIG], il faut juste enlever les opérations inutiles (soustraction, division, multiplication).
- La preuve ne vient pas directement de [SCH], bien qu'elle en soit fortement inspirée. L'essentiel pour ce développement est de ne pas faire la preuve pour les mots entiers mais bien pour les variables uniquement. La propriété à prouver par récurrence est légèrement modifiée, mais elle guide en suite presque

complètement la preuve (il faut juste se souvenir de l'utilisation du lemme fondamental des grammaires).

## Exemple de tableau



## Références

- [TIG] *Modern Compiler implementation in Java (Tiger Book)*, A.W. Appel
- [SCH] *Compilation : Analyse lexicale et syntaxique*, Romain Legendre, François Schwarzentruher