

Chapitre 4 : Analyse syntaxique

4.1 Dérivation la plus à gauche et arbre de dérivation

4.1.1 Définition d'une grammaire non contextuelle

Soit une grammaire $G (VT, VN, S, P)$

VT : ensemble des symboles terminaux de la grammaire (unités lexicales)

VN : ensemble des symboles non terminaux de la grammaire (variables syntaxiques qui dénotent un ensemble de chaînes)

S : l'axiome est un non terminal particulier, tel que l'ensemble des chaînes qu'il dénote est le langage défini par la grammaire.

P : ensemble de règles de production de la grammaire; spécifient la manière dont les terminaux et les non terminaux peuvent être combinés pour former les chaînes.

Exemple

La grammaire constituée des productions suivantes définit des expressions arithmétiques simples :

$\text{expr} \rightarrow \text{expr op expr}$

$\text{expr} \rightarrow (\text{expr})$

$\text{expr} \rightarrow - \text{expr}$

$\text{expr} \rightarrow \text{id}$

$\text{op} \rightarrow +$

$\text{op} \rightarrow -$

$\text{op} \rightarrow *$

$\text{op} \rightarrow /$

$\text{op} \rightarrow \uparrow$

Dans cette grammaire les symboles terminaux sont : $\text{id} + - * / \uparrow ()$, les symboles non terminaux sont expr , et op et l'axiome est expr

En abrégé:

$\text{expr} \rightarrow \text{expr op expr} | (\text{expr}) | - \text{expr} | \text{id}$

$\text{op} \rightarrow + | - | * | / | \uparrow$

4.1.2 Définition d'une Dérivation

Nous disons que $\alpha A \beta \Rightarrow \alpha \gamma \beta$ si $A \rightarrow \gamma$ est une production et α et β sont des chaînes arbitraires de symboles grammaticaux.

Si $\alpha_1 \Rightarrow \alpha_2 \Rightarrow \dots \Rightarrow \alpha_n$, on dit que α_1 se dérive en α_n .

Le symbole \Rightarrow signifie "se dérive en une étape"

Pour dire "se dérive en zéro, une ou plusieurs étapes" on peut utiliser le symbole $*\Rightarrow$

Donc

$\alpha * \Rightarrow \alpha$ pour une chaîne quelconque α et

Si $\alpha * \Rightarrow \beta$ et $\beta \Rightarrow \gamma$, alors $\alpha * \Rightarrow \gamma$

$+ \Rightarrow$ signifie "se dérive en une ou plusieurs étapes"

Soit une grammaire G et S son axiome; on peut utiliser la relation $+ \Rightarrow$ pour définir $L(G)$, le langage engendré par G . On dit qu'une chaîne de terminaux w appartient à $L(G)$ ssi $S + \Rightarrow w$. La chaîne w est appelée phrase de G .

Un langage qui peut être engendré par une grammaire est dit langage non contextuel.

Si $S * \Rightarrow \alpha$, où α peut contenir certains non terminaux, on dit que α est une protophrase de G .

Exemple

Soit la grammaire $G (VT, VN, E, P)$

$E \rightarrow E+E|E^*E|(E)|-E|id$ (3)

La chaîne $-(id+id)$ est une phrase de la grammaire (3) car on a la dérivation:

$E \Rightarrow -E \Rightarrow -(E) \Rightarrow -(E+E) \Rightarrow -(id+E) \Rightarrow -(id+id)$ (4)

Les chaînes $E, -E, -(E), \dots, -(id+id)$ sont toutes des proto-phrases de cette grammaire.

On écrit $E * \Rightarrow -(id+id)$ pour indiquer que E se dérive en $-(id+id)$

A chaque étape d'une dérivation, on doit faire deux choix :

- Il faut choisir le non terminal à remplacer
- Quelle alternative utiliser pour ce non terminal

Dérivation gauche : Seul le non terminal le plus à gauche est remplacé à chaque étape. On

écrit $\underset{g}{\alpha} \Rightarrow \underset{g}{\beta}$ on peut alors réécrire (4)

$E \underset{g}{\Rightarrow} -E \underset{g}{\Rightarrow} -(E) \underset{g}{\Rightarrow} -(E+E) \underset{g}{\Rightarrow} -(id+E) \underset{g}{\Rightarrow} -(id+id)$ (4)

Chaque étape d'une dérivation gauche peut s'écrire:

$\omega A \gamma \xRightarrow{g} \omega \delta \gamma$ ou ω est formé uniquement de terminaux, $A \rightarrow \delta$ est la production utilisée et γ est une chaîne de symboles grammaticaux.

α se dérive en β par une dérivation gauche est notée $\alpha \xRightarrow{g} \beta$

Si $S \xRightarrow{g^*} \alpha$ on dit que α est une proto-phrasé gauche de la grammaire considérée.

Dérivation droite : le non terminal le plus à droite est remplacé à chaque étape.