

Algorithme de Cocke - Younger - Kasami

Référence : Partie 4.2.3 du Cours

Idee : Décider si un mot est engendré par une grammaire. Utile pour transformer une suite de lexèmes en un arbre de syntaxe en analyse syntaxique lors de la compilation.

Définition 1 : On appelle **grammaire hors-contexte** un tuple (Σ, N, S, R) avec :

- Σ un alphabet de symboles terminaux
- N un alphabet de symboles non-terminaux
- S un symbole de départ appelé axiome
- R un ensemble de règles de $N \times (\Sigma \cup N)^*$ noté $X \rightarrow u_1 \dots u_n$.

Définition 2 : On dit que **u se dérive en v** si $u = \alpha X \beta$, $v = \alpha u_1 \dots u_n \beta$ et $X \rightarrow u_1 \dots u_n \in R$.
On appelle ce processus la **dérivation**.
Un mot appartient au langage d'une grammaire s'il existe une suite de dérivations de l'axiome au mot.

Propriété 3 : Toute grammaire hors contexte est équivalente à une grammaire dont les règles sont de la forme $X \rightarrow a$ ou $X \rightarrow YZ$, $a \in \Sigma$ et $Y, Z \in N$. (grammaire quadratique).

Problème 6: Entrée: grammaire G hors contexte sous forme quadratique, mot w
 Sortie: Décide si $w \in L(G)$.

Idee 5: On utilise la programmation dynamique pour calculer les $E_{i,j}$ pour $i, j \in [1, n]$ avec $n = |w|$, où $E_{i,j}$ est l'ensemble des variables X telles que $w[i:j] \in L_G(X)$.

Propriété 6: On a les relations suivantes:
 $\forall i \in [1, n], E_{i,i} = \{X \in N \mid X \rightarrow w[i] \in R\}$
 $\forall i \in [1, n], \forall j \in [i+1, n], E_{i,j} = \{X \in N \mid \exists k \in [i, j-1] \exists Y, Z \in N \text{ tels que } X \rightarrow YZ \in R, Y \in E_{i,k} \text{ et } Z \in E_{k+1,j}\}$

Fonction $CYK(w: \text{mot})$:

$n := \text{longueur}(w)$

$E_{i,j} := \{\}$ pour $i, j \in [1, n]$

Pour i de 1 à n faire

 Pour $S \in N$ faire

 Si $S \rightarrow w[i] \in R$ faire

$E_{i,i} := S :: E_{i,i}$

 Fin Si

Pour i de n à 1 faire

 Pour j de $(i+1)$ à n faire

 Pour k de i à $j-1$ faire

 Pour $Z \rightarrow XY \in R$ faire

 Si $X \in E_{i,k}$ et $Y \in E_{k+1,j}$ faire

$E_{i,j} := Z :: E_{i,j}$

Retourner $S \in E_{1,n}$

Théorème 6: Cet algorithme est cubique en la taille du mot.

Preuve: On itère i, j et k qui peuvent prendre un nombre de valeurs inférieur chacun par n . On a alors une complexité temporelle de $O(n^3 \times |R| \times |N|)$ pour des structures de données naïves, ce qui est cubique en n .

Remarque 7: On ne prend pas en compte la taille de la grammaire car elle est supposée fixe. On l'intègre donc à la constante.

Exemple 8:

$$\begin{aligned} S &\rightarrow \circ \\ S &\rightarrow SS_+ \\ S_+ &\rightarrow V_+ S \\ V_+ &\rightarrow + \\ S' &\rightarrow SS_+ \end{aligned}$$

	$\circ$	$+$	$\circ$	$+$	$\circ$
$\circ$	S	$[]$	S, S'	$[]$	S, S'
$+$	$/$	$/$	V_+	S_+	$[]$ S_+
$\circ$	$/$	$/$	S	$[]$	S, S'
$+$	$/$	$/$	$/$	V_+	S_+
$\circ$	$/$	$/$	$/$	$/$	S