

COCKE-YOUNGER-KASAMI

Antoine DEQUAY

21 septembre 2022

Notes

- Prof : .
- Leçon : 907, 915, 923, 931.
- Références :
 - LE BARBENCHON.

Définition 1 *Forme normale de CHOMSKY.* On dit qu'une grammaire algébrique $G = (\mathcal{N}, \mathcal{T}, S, \mathcal{R})$ est sous forme normale de CHOMSKY si elle ne contient que des règles de la forme $A \in \mathcal{N} \rightarrow a \in \mathcal{T}$ ou $A \in \mathcal{N} \rightarrow A_1 A_2 \in \mathcal{N}\mathcal{N}$.

Définition 2 *Problème du mot.* On définit le problème du MOT :

$\left\{ \begin{array}{l} \text{entrée : Un mot } w = w_1 \dots w_n \text{ une grammaire algébrique } G \text{ sous forme normale de CHOMSKY,} \\ \text{sortie : oui si } w \in L(G), \text{ non sinon.} \end{array} \right.$

On cherche un algorithme permettant de résoudre ce problème.

Pour cela, notons, pour $i, j \in \llbracket 1, n \rrbracket$, $i \leq j$:

$$E_{i,j} = \{A \in \mathcal{N}, A \rightarrow^* w_i \dots w_j\}.$$

On a donc $w \in L(G) \iff S \in E_{1,n}$. On cherche donc à calculer $E_{1,n}$.

Proposition 3 Pour tout $i \in \llbracket 1, n \rrbracket$,

$$E_{i,i} = \{A \in \mathcal{N}, A \rightarrow w_i \in \mathcal{R}\}.$$

Preuve. Au vue de la forme d'une grammaire de CHOMSKY ($A \rightarrow \varepsilon$ n'existe pas), un mot construit en utilisant une règle de la forme $A \rightarrow BC$ contiendra au moins 2 lettres, d'où le résultat. □

Proposition 4 Pour $1 \leq i < j \leq n$, on a :

$$E_{i,j} = \bigcup_{k=i}^{j-1} \bigcup_{\substack{B \in E_{i,k} \\ C \in E_{k+1,j}}} \{A \in \mathcal{N}, A \rightarrow BC \in \mathcal{R}\}$$

Preuve.

\supseteq : Immédiate ! Il suffit de l'écrire.

\subseteq : Comme $i \neq j$, $w_i \dots w_j$ possède au moins 2 lettres, donc si $A \in E_{i,j}$, A s'écrit forcément sous la forme $A \rightarrow BC$, $B, C \in \mathcal{N}$, d'où $BC \rightarrow^* w_i \dots w_j$. Par lemme de factorisation, il existe $k \in \mathbb{N}$ et des dérivations $B \rightarrow^* w_i \dots w_k$ et $C \rightarrow^* w_{k+1} \dots w_j$. Par la forme d'une grammaire de CHOMSKY, il vient donc $i \leq k < j$ et $B \in E_{i,k}$, $C \in E_{k+1,j}$, d'où le résultat. □

Pour calculer par programmation dynamique successivement les $E_{i,j}$ pour arriver à $E_{1,n}$, on utilise la représentation matricielle suivante :

$$\begin{pmatrix} E_{1,1} & \dots & E_{1,i} & \dots & E_{1,j} & \dots & E_{1,n} \\ & \ddots & \vdots & & \vdots & & \vdots \\ & & E_{i,i} & \rightarrow & E_{i,j} & \dots & E_{i,n} \\ & & & \ddots & \uparrow & & \vdots \\ & & & & E_{j,j} & \dots & E_{j,n} \\ & & & & & \ddots & \vdots \\ & & & & & & E_{n,n} \end{pmatrix}$$

et on parcourt les diagonales dans le sens \nearrow .

Théorème 5 Ainsi, l'algorithme suivant permet bien de résoudre le problème du mot :

Algorithm 1: CYK(w, G)

Entrée: Un mot w et une grammaire G .

Sortie : Un booléen indiquant si $w \in L(G)$.

Initialiser $E_{i,j} = \emptyset$;

for $i \leftarrow 1$ **to** n **do**

| **for** $A \rightarrow a \in \mathcal{R}$ **do**

| | **if** $a = w_i$ **then**

| | | $E_{i,i} \leftarrow E_{i,i} \cup \{A\}$

for $d \leftarrow 2$ **to** n **do**

| **for** (i, j) sur la d -diagonale supérieure **do**

| | **for** $k \leftarrow i$ **to** $j - 1$ **do**

| | | **for** $A \rightarrow B_1 B_2 \in \mathcal{R}$ **do**

| | | | **if** $B_1 \in E_{i,k}$ et $B_2 \in E_{k+1,j}$ **then**

| | | | | $E_{i,j} \leftarrow E_{i,j} \cup \{A\}$

return $w \in E_{1,n}$.

Remarque On peut par exemple implémenter ces ensemble dans une matrice indicée par (i, j) , ayant dans chaque case une liste de booléens indexée sur les non-terminaux. La complexité temporelle est alors en $O(n^3 \#\mathcal{R})$, et la complexité spatiale en $O(n^2 \#\mathcal{N})$.

Remarque — Quand se ramène à une forme de CHOMSKY, on perd ε s'il est dans le langage,

— Dans le cas des machines de TURING, le problème est indécidable,

— Il existe des problèmes indécidables dans le cas des grammaires algébriques.