

CYK [l'autom p 133 pour l'algo]

NP : 1^{er} jet = 15'15

A utiliser maxima de place au début

L'algorithme de Cocke Younger Karpami prend en entrée

un mot $w = w_1 \dots w_m$ et une grammaire G sous forme normale de Chomsky (d'axiome S)

(c'est ses productions sont de la forme $A \rightarrow a$ ou $A \rightarrow B_1 B_2$, terminaux en minuscules et non terminaux en majuscules)

Ensuite, il donne oui si $w \in L(G)$ et non sinon.

- w est engendré par G

$\forall 1 \leq i \leq j \leq m$, on mette $E_{ij} = \{ \text{non terminaux qui engendent } w_i \dots w_j \}$

On sait que $w \in L(G) \Leftrightarrow S \in E_{1m}$. On veut donc $\forall E_{1m}$

Pour ce faire, on calcule les E_{ij} en utilisant la relation suivante :

$$\forall 1 \leq i \leq j \leq m, E_{ij} = \bigcup_{\substack{A \rightarrow B_1 B_2 \\ B_1 \in E_{ik} \\ B_2 \in E_{k+1j} \\ i \leq k \leq j}} \{A\}$$

En effet, si $B_1 \xrightarrow{*} w_i \dots w_k$, $B_2 \xrightarrow{*} w_{k+1} \dots w_j$ et $A \rightarrow B_1 B_2$ alors

$A \rightarrow w_i \dots w_j$ car $A \in E_{ij}$; et réciproquement, si $A \rightarrow w_i \dots w_j$ (mot d'au-
tant de paths que $i+j$) alors $\exists B_1, B_2, k$ tq $B_1 \in E_{ik}$, $B_2 \in E_{k+1j}$ et $i \leq k \leq j$

car G est sous forme de Chomsky

donne l'ordre de K des E_{ij}

Pour calculer E_{ij} ($i < j$) on a besoin des E_{ik} et des E_{k+1j} avec $i \leq k \leq j$

On représente cette dépendance du tableau suivant :

E_{11}	\dots	E_{1i}	\dots	E_{ij}	\dots	E_{im}
\vdots		\vdots		\vdots		\vdots
$E_{1j} = \emptyset$	\dots	$E_{1i} = \emptyset$	\dots	E_{ij}	\dots	E_{im}
\vdots		\vdots		\vdots		\vdots
$E_{ji} = \emptyset$	\dots	$E_{jc} = \emptyset$	\dots	E_{ij}	\dots	E_{jm}
\vdots		\vdots		\vdots		\vdots
$E_{m1} = \emptyset$	\dots	$E_{mi} = \emptyset$	\dots	$E_{mj} = \emptyset$	\dots	E_{mm}

on $\boxed{\quad}$ = ce qu'il faut pour $K E_{ij}$

Les E_{ij} sous la diagonale sont \emptyset

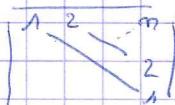
car pour eux, l'indice de début de

mot est \geq celui de fin de mot

on calcule donc les E_{ij} dans l'ordre suivant : la diagonale (= cas de base) et on

peut (au vi), $E_{ii} = \{A \mid A \rightarrow w_i \in \text{production de } G\}$ puis la superdiagonale ... jusqu'à E_{mm}

Ordre des calculs :



D'où l'algorithme :

Initialiser tous les E_{ij} à \emptyset

Pour $i = 1 \text{ à } m$

| Pour $A \rightarrow a \in G$

| | Si $a = w_i$ alors $E_{ii} = E_{ii} \cup \{A\}$

} calcule la diagonale

Pour $d = 2 \text{ à } m$

| Pour E_{ij} sur la diagonale d

| | Pour $k = i \text{ à } j-1$

| | | Pour $A \rightarrow B_1 B_2 \in G$

| | | | Si $B_1 \in E_{ik}$ et $B_2 \in E_{k+1,j}$ alors $E_{ij} = E_{ij} \cup \{B\}$

} pour les diagonales suivantes

Renvoyer $S \in E_m$

On obtient une complexité en $m|G| + m^3|G| = O(m^3|G|)$ où $|G| = mb$ de règles de G et $O(m^3|G|)$ où $|G| = mb$ de symboles des règles

(*) Mise sous forme de Chomsky d'une grammaire propre (=Pas de $A \rightarrow \epsilon$ ou de $A \rightarrow A'$)

On commence par obtenir des productions de la forme $A \rightarrow a$ et $A \rightarrow B_1 \dots B_m$

en introduisant pour tout terminal b_i un non terminal T_i et en remplaçant

les t_i par T_i dans les productions de G

(les membres duplo et l'autre)

+ ajout $T_i \rightarrow t_i$

Puis, pour chaque règle de la forme $A \rightarrow B_1 \dots B_m$ on introduit des non terminaux

B'_2, \dots, B'_{m-1} et on remplace cette règle par $A \rightarrow B_1 B'_2, B'_2 \rightarrow B_2 B'_3, B'_3 \rightarrow B_3 B'_{i+1} \dots$

$B'_{m-1} \rightarrow B_{m-1} B_m$.

Ex : $S \rightarrow a | bSb | Sb$ devient $S \rightarrow a | ASA | SB$ puis

$A \rightarrow a$

$B \rightarrow b$

$S \rightarrow a | AA' | SB$

$A' \rightarrow SB$

terminaux et non terminaux

Complexité de la mise sous forme de Chomsky ($|b| =$ nombre de symboles utilisés pour écrire les règles de G)

1^{ère} étape : En ajoutant les $T_i \rightarrow t_i$, on ajoute au plus $2 \times mb$ de terminaux $\leq 2|G|$ symboles au apparaissant dans les règles

Mettre les $A \rightarrow B_1 B_2 C$ en $A \rightarrow B_1 T_2 C$ n'augmente pas $3mb$ de symboles

2^{ème} étape : Passer de $A \rightarrow B_1 \dots B_m$ à $A \rightarrow B_1 B'_2 \dots B'_{m-1} \rightarrow B_{m-1} B_m$ remplace $m+1$ symboles par $\leq 3m$

Donc complexité en $O(16|G|)$