

# Théorie des Langages - EISTI - ING 1

Yannick Le Nir

Ecole Internationale des Sciences du Traitement de l'Information

yannick.lenir@eisti.fr

## Langages décidables et hiérarchie de classes

- ▶ Les langages de type 3 : rationnels ou réguliers
- ▶ Les langages de type 2 : algébriques ou hors contexte
- ▶ Les langages de type 1 : sensibles au contexte
- ▶ Les langages de type 0 : tous les autres décidables

## Définition

Une grammaire  $G = \langle T, N, S, P \rangle$  est de type 3 si les règles de production sont de la forme :

$A \rightarrow a$  où  $A \in N$  et  $a \in T^*$   $A \rightarrow B a$  (ou  $a B$ ) où  $A, B \in N$   
et  $a \in T^*$

## Langage associé

Un langage est de type 3 s'il peut être engendré par une grammaire de type 3.

## Domaines

- ▶ Occurrence de motifs dans une chaîne (Recherche d'informations)
- ▶ Expressions régulières (Shell, C, emacs)
- ▶ Séquence de l'ADN (Génôme)
- ▶ Apprentissage de grammaires pour l'IA

# Exemple de grammaire

## Affectation numérique

La grammaire  $G = \langle T, N, S, P \rangle$  du cours précédent pour l'analyse lexicale de l'affectation numérique est de type 3 :

- ▶  $T = \text{lettre} \cup \text{chiffre} \cup \{+, -, *, /, =, .\}$
- ▶  $N = \{\text{mot}, \text{nombre}, \text{opérateur}, \text{nombre}, \text{identifiant}\}$
- ▶  $S = \text{mot}$
- ▶  $P =$   
$$\left\{ \begin{array}{l} \text{mot} \rightarrow \text{opérateur}, \\ \text{opérateur} \rightarrow + \mid - \mid * \mid / \mid =, \\ \text{mot} \rightarrow \text{nombre}, \\ \text{nombre} \rightarrow (\text{chiffre}^+) \mid (\text{chiffre}^+).(\text{chiffre}^+), \\ \text{mot} \rightarrow \text{identifiant}, \\ \text{identifiant} \rightarrow \text{lettre} \mid \text{identifiant}(\text{lettre} \mid \text{chiffre}) \end{array} \right\}$$

## Définition

Une grammaire  $G = \langle T, N, S, P \rangle$  est de type 2 si les règles de production sont de la forme :

$A \rightarrow \alpha$  où  $A \in \mathcal{N}$  et  $\alpha \in (N \cup T)^*$

## Langage associé

Un langage est de type 2 s'il peut être engendré par une grammaire de type 2.

## Exemple de grammaire

Le fameux langage  $a^n b^n$  peut être engendré par la grammaire hors contexte suivante :

- ▶  $T = \{a, b\}$
- ▶  $N = \{S\}$
- ▶  $S = S$
- ▶  $P = \left\{ \begin{array}{l} S \rightarrow a S b, \\ S \rightarrow a b \end{array} \right\}$

## Domaines d'application

- ▶ Langages de programmation
- ▶ La plupart des constructions des langues naturelles

## Grammaires de type 1

Une grammaire  $G = \langle T, N, S, P \rangle$  est de type 1 si les règles de production sont de la forme :

$u A v \rightarrow u w v$  où  $A \in N$ ,  $u, v \in T^*$  et  $w \in (N \cup T)^*$

## Grammaires de type 0

Une grammaire  $G = \langle T, N, S, P \rangle$  est de type 0 si les règles de production sont quelconques.

## Théorèmes

- ▶ Une grammaire n'engendre qu'un seul langage. La réciproque est fausse.
- ▶ Les différentes familles de langages sont incluses les unes dans les autres :  $L_3 \subset L_2 \subset L_1 \subset L_0$

## Définition

Une grammaire de type 2 (sans  $\varepsilon$ ) est dite sous forme normale de Chomsky si et seulement si toutes les règles sont de la forme :

$$\begin{aligned} A &\rightarrow a \text{ (où } a \in T) \\ A &\rightarrow BC \text{ (où } B, C \in N) \end{aligned}$$

## Théorème

Tout langage hors-contexte sans  $\varepsilon$  peut être engendré par une grammaire en forme normale de Chomsky.

## Algorithme

1. remplacer tous les terminaux  $x$  en partie droite des règles par des non-terminaux  $X$  en ajoutant les règles  $X \rightarrow x$
2. Toute règle  $X \rightarrow YZW$  est remplacée par  $X \rightarrow YV$  et  $V \rightarrow ZW$
3. remplacer les règles  $X \rightarrow Y$  par  $X \rightarrow WZ$  si  $Y \rightarrow WZ$

## Exemple

Le langage  $a^n b^n$  peut être engendré par la grammaire sous forme normale de Chomsky

suivante :  $\langle \{a, b\}, \{A, B, S\}, S, P \rangle$  avec

$$P = \left\{ \begin{array}{l} S \rightarrow A B, S \rightarrow A X, X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Forme normale de Chomsky

- ▶ La Forme Normale de Chomsky permet l'obtention d'un algorithme efficace pour reconnaître l'appartenance à un langage hors-contexte.
- ▶ Cet algorithme est dû à Cocke, Kasami et Younger (CKY).

## Idée de l'algorithme

- ▶  $G$  : grammaire sous forme normale de Chomsky
- ▶  $w$  : mot de longueur  $n$
- ▶ Question :  $w \in L(G)$  ?
- ▶ Chercher pour chaque sous-mot  $m$  de  $w$ ,  $X \in N$  tels que  $X \rightarrow^* m$
- ▶ A la sortie, vérifier si le symbole axiome  $S$  fait partie des non-terminaux obtenus.

## Construction

- ▶ Tableau triangulaire : colonnes numérotées par  $i = 1, 2, \dots, n$  (les positions de début de mot dans  $w$ ) et lignes par  $j = 1, 2, \dots, n$  (les longueurs possibles).
- ▶ Remplissage de la ligne 1 puis 2 ...
- ▶ La  $p$ ième case de la ligne  $k$  correspond aux non-terminaux qui peuvent engendrer  $w[p, k]$ .
- ▶ On examine donc toutes les coupures du mot  $w[p, k]$  en deux sous-mots :  $w[p, l]$  et  $w[p + l, k - l]$ .
- ▶ Pour tous les  $Y$  possibles et tous les  $l$  compris entre 1 et  $k$ , on regarde toutes les expressions  $X_p X_{p+l}$  en recherchant s'il existe  $Y$  dans la grammaire tel que  $Y \rightarrow X_p X_{p+l}$ .

## Déroulement du CKY

4				
3				
2				
1				
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3				
2				
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3				
2	$\emptyset$			
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3				
2	$\emptyset$	S		
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3				
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3				
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3	$\emptyset$			
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3	$\emptyset$			
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3	$\emptyset$	X		
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3	$\emptyset$	X		
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4				
3	$\emptyset$	X		
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4	$\emptyset$			
3	$\emptyset$	X		
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4	$\emptyset$			
3	$\emptyset$	X		
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Déroulement du CKY

4	S			
3	$\emptyset$	X		
2	$\emptyset$	S	$\emptyset$	
1	A	A	B	B
input	a	a	b	b

$$P = \left\{ \begin{array}{l} S \rightarrow A B, \\ S \rightarrow A X, \\ X \rightarrow S B, \\ A \rightarrow a, \\ B \rightarrow b \end{array} \right\}$$

## Algorithme

```
Pour i = 1 à n faire :  
    V[i, 1] <-- {A; A -> a est une règle  
                et le ième symbole de w est a}  
  
Pour j = 2 à n faire :  
    pour i = 1 à n - j + 1 faire  
        V[i, j] <--  $\emptyset$  ;  
        pour k = 1 à j - 1 faire  
            V[i, j] <--- V[i, j] union  
            {A ; A -> BC est une règle, B appartient à V[i, k]  
             et C appartient à V[i+k, j-k]}
```

## Complexité

- ▶  $n^2$  fois une action consistant à couper en deux un mot d'au plus  $n$  lettres
- ▶  $n$  coupures à effectuer à chaque fois
- ▶ Complexité de l'algorithme de l'ordre de  $n^3$  par rapport à la longueur  $n$  du mot d'entrée.
- ▶ Les langages hors-contexte peuvent être reconnus en un temps polynomial.