



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'enseignement supérieur et de la recherche scientifique
Université Larbi Ben M'Hidi Oum El Bouaghi

Cours traitement du langage
naturel



CHAPITRE 4 : Analyse syntaxique

Contenu du Chapitre :

01

Grammaires formelles et
contextuelles

02

Analyse syntaxique
basée sur les règles


03

Méthodes d'analyse
syntaxique probabiliste





01 Grammaires formelles et contextuelles





Définition :

- Une grammaire formelle est un système mathématique permettant de décrire les structures syntaxiques d'un langage, qu'il soit naturel ou artificiel.
- Elle est constituée de règles de production qui définissent comment les phrases sont construites à partir d'un ensemble de symboles.



Grammaires formelles et contextuelles



Composants d'une grammaire formelle :

Une grammaire est souvent représentée par un quadruplet $G=(N,T,P,S)$ où :

N : Ensemble de symboles **non-terminaux**

T : Ensemble de symboles terminaux

P : Ensemble de règles de production, définissant comment les non-terminaux se transforment.

S : Symbole de départ



Grammaires formelles et contextuelles



Types de grammaire :

La hiérarchie de **Chomsky** classe les grammaires formelles selon leur complexité et leur capacité à décrire les langages.

Elle comporte quatre types, du plus restreint (Type 3) au plus général (Type 0)



Grammaires formelles et contextuelles

Types de grammaire

Type 3 : Grammaires régulières

01

02

Type 2 : Grammaires hors-contexte (Context-Free Grammars, CFG)

Type 1 : Grammaires sensibles au contexte (Context-Sensitive Grammars, CSG)

03

04

Type 0 : Grammaires récursivement énumérables.



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires régulières (Type 3)

- Ce sont les grammaires les plus simples
- Chaque règle de production suit une forme stricte :

$$A \rightarrow aB \text{ ou } A \rightarrow a$$

Où A et B sont des non-terminaux, et a est un terminal



Grammaires formelles et contextuelles



Types de grammaire :

Exmple de grammaire de types 3

Expliqué en
python

$S \rightarrow aS | bS | \epsilon$

Cette grammaire génère toutes les chaînes composées de 'a' et 'b' : y compris la chaîne vide



[ab]* Grammaires formelles et contextuelles



Types de grammaire :

Exmple de grammaire de types 3 $S \rightarrow aS | bS | \epsilon$

Expliqué en
python

import `re` : le module `re` (regular expressions), qui permet de travailler avec les expressions régulières.

```
regex = r'^[ab]*$'
```

- `^` : Début de la chaîne
- `[ab]*` : Accepte 0 ou plus caractères a ou b (accepte la chaîne vide)
- `[ab]+` → Accepte au moins 1 caractère a ou b (rejette la chaîne vide)
- `[]` : Définit un ensemble de caractères autorisés (a et b uniquement)
- `*` : Répétition de 0 à l'infini des caractères dans `[ab]`
- `$` : Fin de la chaîne



Grammaires formelles et contextuelles



Types de grammaire :

Caractéristiques et applications des Grammaires régulières (Type 3)

- Génèrent des langages réguliers, souvent représentés par des expressions régulières ou des automates finis
- Ne permettent pas de modéliser des structures imbriquées

Appliqués à :

- la reconnaissance de modèles simples comme les mots-clés dans un texte.
- Analyse lexicale dans les compilateurs.



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires hors-contexte (Type 2)

- Une grammaire est dite hors-contexte si ses règles ont la forme : $A \rightarrow \alpha$
- Où A est un non-terminal et α est une chaîne contenant des terminaux et/ou non-terminaux.
- Produisent les **langages hors contexte**, reconnus par des **automates à pile**.



Grammaires formelles et contextuelles



Types de grammaire :

Exemple de Grammaires hors-contexte (Type 2)

Expliqué
en
python

$S \rightarrow aSb \mid \epsilon$: cette grammaire génère des chaînes comme $a^n b^n$, par exemple "ab", "aabb", "aaabbb", etc.

abab" : invalide car elle n'est pas de la forme $a^n b^n$ (les 'a' et 'b' sont mélangés).



Grammaires formelles et contextuelles



Types de grammaire :

Exemple de Grammaires hors-contexte (Type 2) : $S \rightarrow aSb \mid \epsilon$

Expliqué
en
python

```
#Grammaires hors-contexte (Type 2)
def is_context_free(string):
    n = len(string) // 2
    if len(string) % 2 != 0:
        return False
    return string[:n] == 'a' * n and string[n:] == 'b' * n
```

- `string[:n] == 'a' * n`
- Vérifie si la première moitié est composée uniquement de a
- `string[n:] == 'b' * n`
- Vérifie si la deuxième moitié est composée uniquement de b



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires hors-contexte (Type 2)

Ces types de grammaires sont appliqués à la:

- Construction d'arbres syntaxiques pour les phrases
- Modélisation des langages de programmation et de structures de phrases simples.



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires sensibles au contexte (Type 1)

- Ces grammaires permettent des règles où le contexte autour d'un non-terminal influence son remplacement.
- Une règle typique a la forme : $\alpha A \beta \rightarrow \alpha \gamma \beta$
- Où A est un non-terminal, α , β , et γ sont des chaînes de terminaux et de non-terminaux.
- De plus, $|\gamma| \geq |A|$, garantissant une expansion ou une conservation de la taille



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires sensibles au contexte (Type 1)

Appliqués à la :

- Modélisation des règles syntaxiques avancées (accords, morphologie)
- Analyse des langues riches en morphologie comme l'arabe ou le russe



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires sensibles au contexte (Type 1)

Grammaire :

Variables : S, A, BS, A, BS, A, B

Alphabet terminal : a, ba, ba, b

Production :

- $S \rightarrow aSb$
- $S \rightarrow AB$
- $AB \rightarrow aB$
- $B \rightarrow b$

générer des chaînes de la forme $a^n b^n$ comme aabb



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires sensibles au contexte (Type 1)

Exemple :

Accord entre sujet et verbe dans une langue :

Sujet (singulier) Verbe (singulier) $\rightarrow$ Phrase

Sujet (pluriel) Verbe (pluriel) $\rightarrow$ Phrase



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires récursivement énumérables (Type 0))

Les grammaires de type 0 permettent des règles de production totalement libres, sauf qu'au moins un non-terminal doit apparaître dans la partie gauche

Une règle a la forme : $\alpha \rightarrow \beta$

Où α et β sont des chaînes de terminaux et/ou non-terminaux.



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires récursivement énumérables (Type 0))

- Ces grammaires génèrent des **langages récursivement énumérables**, les plus généraux de la hiérarchie.
- Peuvent modéliser tout calcul pouvant être effectué par une machine de Turing.
- Utilisé en théorie des automates et des langages formels
- Pas directement utilisée en TLN en raison de sa complexité



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires récursivement énumérables (Type 0))

Soit $G = (N, T, P, S)$ où :

$N = \{S, A, B\}$ est l'ensemble des symboles non-terminaux

$T = \{a, b, c\}$ est l'ensemble des symboles terminaux

S est le symbole de départ

P est l'ensemble des règles de production suivantes :

$S \rightarrow aSBC$

$S \rightarrow aBC$

$CB \rightarrow BC$

$aB \rightarrow ab$

$bB \rightarrow bb$

$bC \rightarrow bc$

$cC \rightarrow cc$

Cette grammaire génère des chaînes de la forme $a^n b^n c^n$



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires sensibles au contexte (Type 1)

```
class CSGValidator:
    def __init__(self):
        # Définition de la grammaire qui génère  $a^n b^n c^n$ 
        self.rules = [
            ('S', 'aSBC'),
            ('S', 'aBC'),
            ('CB', 'BC'),
            ('aB', 'ab'),
            ('bB', 'bb'),
            ('bC', 'bc'),
            ('cC', 'cc')
        ]
        self.start_symbol = 'S'
```



Grammaires formelles et contextuelles



Types de grammaire :

Grammaires sensibles au contexte (Type 1)

```
def is_valid_string(self, input_string):  
    if not input_string:  
        return False  
  
    # Validation rapide: la chaîne doit contenir uniquement a, b, c  
    if not all(char in 'abc' for char in input_string):  
        return False  
    a_count = 0  
    b_count = 0  
    c_count = 0  
    i = 0  
    while i < len(input_string) and input_string[i] == 'a':  
        a_count += 1  
        i += 1
```



Grammaires formelles et contextuelles


Récapitulation sur les types des grammaires

	Structure des règles	Langages générés	Complexité	Applications
Types 3	$A \rightarrow aB$ ou $A \rightarrow a$	Langages réguliers	Très faible	Analyse lexicale, expressions régulières.
Types 2	$A \rightarrow \alpha$	Langages hors-contexte	Modérée	Parsing syntaxique, structures imbriquées.
Types 1	$\alpha A \beta \rightarrow \alpha \gamma \beta$	Langages sensibles au contexte	Élevée	Morphologie, accords grammaticaux.
Types 0	$\alpha \rightarrow \beta$	Langages récursivement énumérables	Très élevée	Théorie des langages formels



02

Analyse syntaxique basée sur les règles



Analyse syntaxique basée sur les règles



Définition

- L'analyse syntaxique basée sur des règles est une approche clé dans la validation des langages formels
- Elle repose sur l'application de règles de production définies dans une grammaire, afin de structurer une chaîne de symboles d'entrée sous la forme d'un arbre syntaxique
- Une règle de production associe un non-terminal à une séquence de symboles terminaux et non-terminaux, permettant ainsi de décomposer ou de générer des chaînes de caractères valides



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique :

Analyse Descendante (Top-Down Parsing)

- L'analyse commence avec le symbole de départ de la grammaire (généralement un non-terminal) et cherche à réduire cette catégorie vers les terminaux en appliquant les règles de production.
- Le processus suit la structure de la grammaire, en appliquant successivement les règles pour tenter de dériver la chaîne d'entrée
- Une approche courante dans l'analyse descendante est **l'analyse récursive descendante**, où chaque non-terminal est associé à une fonction récursive qui applique les règles de production correspondantes.



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique :

Méthodes de l'analyse Descendante (Top-Down Parsing)

- Algorithme LL(k): Left-to-right, Leftmost derivation, avec k symboles d'anticipation
- Analyse récursive descendante: implémentation directe par des fonctions récursives



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Exemple d'Analyse Descendante :

Prenons l'exemple de l'expression arithmétique $(3 + 4) * 5$ avec une grammaire donnée. L'analyse descendante commencerait par le symbole de départ Expression et appliquerait les règles suivantes :

1. **Expression** $\rightarrow$ Expression + Terme
2. Puis, **Expression** $\rightarrow$ Terme (en raison de la structure de l'expression)
3. Enfin, **Terme** $\rightarrow$ Facteur, où **Facteur** devient (Expression), et ainsi de suite jusqu'à obtenir une dérivation complète



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing)

Contrairement à l'analyse descendante, l'analyse montante commence avec les terminaux (symboles de la chaîne d'entrée) et essaie de les combiner en appliquant des réductions successives pour obtenir le symbole de départ



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing)

- **Algorithme LR(k)**: Left-to-right, Rightmost derivation in reverse, avec k symboles d'anticipation
- **Algorithme CYK (Cocke-Younger-Kasami)**: utilise la programmation dynamique pour l'analyse



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

Grammaire (en CNF) :

1. $S \rightarrow NP VP$ (une phrase est constituée d'un groupe nominal suivi d'un groupe verbal)
2. $NP \rightarrow Det N$ (un groupe nominal est un déterminant suivi d'un nom)
3. $VP \rightarrow V NP$ (un groupe verbal est un verbe suivi d'un groupe nominal)
4. $Det \rightarrow Le$ (le déterminant "Le")
5. $N \rightarrow chat$ (le nom "chat")
6. $V \rightarrow mange$ (le verbe "mange")



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

Étapes de l'algorithme CYK :

1. Initialisation :

- Nous commençons par préparer une table vide où chaque cellule correspond à un sous-ensemble de la phrase
- La phrase "Le chat mange" a 3 mots, donc nous aurons une table de 3x3 (pour les 3 mots, avec des sous-parties qui sont des combinaisons possibles).



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

Étapes de l'algorithme CYK :

2. Remplissage de la diagonale (analyse des mots individuels) :

Le mot "Le" peut être un **Det**, donc on place **Det** dans la cellule (1,1).

Le mot "chat" peut être un **N**, donc on place **N** dans la cellule (2,2).

Le mot "mange" peut être un **V**, donc on place **V** dans la cellule (3,3)



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

	1	2	3
1	Det		
2		N	
3			V



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

3. Analyse des sous-phrases : À partir de la diagonale, nous analysons les combinaisons possibles entre les mots pour construire des sous-phrases :

- Dans la cellule (1,2), nous cherchons une combinaison entre **Det** (dans (1,1)) et **N** (dans (2,2)). La règle $NP \rightarrow Det N$ nous permet de conclure que la cellule (1,2) peut contenir **NP**.
- Dans la cellule (2,3), nous cherchons une combinaison entre **N** (dans (2,2)) et **V** (dans (3,3)). Il n'y a pas de règle directe pour cela, donc la cellule reste vide.



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

	1	2	3
1	Det	NP	
2		N	
3			V



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

4. Combiner les sous-phrases plus grandes :

Dans la cellule (1,3), nous cherchons une combinaison entre **NP** (dans (1,2)) et **V** (dans (3,3)). La règle $VP \rightarrow V NP$ nous permet de conclure que la cellule (1,3) peut contenir **VP**.
La table finale :



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

	1	2	3
1	Det	NP	VP
2		N	
3			V



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange":

5. Vérification de la phrase complète : Si la cellule en haut à droite (1,3) contient **S** (la règle de départ), alors la phrase est valide selon la grammaire.

Dans cet exemple, la cellule (1,3) contient **VP**, mais pas **S**.

C à d que la phrase "Le chat mange" ne peut pas être générée directement par cette grammaire.

Pour obtenir **S**, il faudrait que le groupe nominal (NP) soit suivi par un groupe verbal (VP), ce qui pourrait être amélioré en réévaluant ou en ajustant la grammaire.



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Analyse Montante (Bottom-Up Parsing) Algorithme CYK

Pour la phrase "Le chat mange": Appliquer CYK Avec cette grammaire

$S \rightarrow NP VP$	<i>(une phrase est un groupe nominal suivi d'un groupe verbal)</i>
$NP \rightarrow Det N$	<i>(un groupe nominal est un déterminant suivi d'un nom)</i>
$VP \rightarrow V$	<i>(un groupe verbal peut être simplement un verbe)</i>
$Det \rightarrow Le$	<i>(le déterminant "Le")</i>
$N \rightarrow chat$	<i>(le nom "chat")</i>
$V \rightarrow mange$	<i>(le verbe "mange")</i>



Analyse syntaxique basée sur les règles



Méthodes d'Analyse Syntaxique : Descendante vs Montante

Limites de l'analyse basée sur les règles

- Difficulté à gérer l'ambiguïté syntaxique
- Complexité d'élaboration des règles pour couvrir tous les cas
- Manque de robustesse face aux erreurs et aux constructions non-standard
- Difficulté à s'adapter à différentes langues ou domaines



Analyse syntaxique basée sur les règles



Arbres Syntaxiques : Représentation Hiérarchique

- L'objectif principal de l'analyse syntaxique est de générer un arbre syntaxique, une structure hiérarchique qui représente la composition de l'expression en fonction des règles de la grammaire.
- Chaque nœud de l'arbre représente une règle de production appliquée, et les feuilles de l'arbre sont les symboles terminaux.



Analyse syntaxique basée sur les règles




Types d'arbres syntaxiques

1. Arbres de constituants (ou de syntagmes)

Ces arbres divisent la phrase en syntagmes hiérarchiques. Ils montrent comment les mots se regroupent pour former des unités grammaticales plus larges.

Exemple : Un étudiant lit un livre



Analyse syntaxique basée sur les règles




Types d'arbres syntaxiques

1. Arbres de dépendance

Ces arbres représentent les relations de dépendance entre les mots. Chaque mot, sauf la racine, dépend d'un autre mot.

Exemple : Un étudiant lit un livre



Analyse syntaxique basée sur les règles



Propriétés de l'Analyse Syntaxique

Ambiguïté syntaxique

Une phrase peut avoir plusieurs arbres syntaxiques valides, révélant une ambiguïté:

Exemple : "Elle regarde l'homme avec un télescope«

Interprétation 1 : Elle utilise un télescope pour regarder l'homme

Interprétation 2 : Elle regarde un homme qui possède un télescope


Ces deux interprétations donnent deux arbres syntaxiques différents





03

Méthodes d'analyse syntaxique probabiliste



Méthodes d'analyse syntaxique probabiliste



Introduction

- L'analyse syntaxique probabiliste utilise des techniques statistiques pour résoudre les ambiguïtés syntaxiques qui surviennent dans le traitement automatique des langues.
- En informatique, cette approche repose sur l'idée que la structure syntaxique la plus probable d'une phrase peut être identifiée à l'aide de modèles probabilistes, souvent formés à partir de grandes quantités de données linguistiques
- Ces méthodes sont particulièrement utiles pour traiter des langues naturelles où les structures syntaxiques peuvent être ambiguës.



Méthodes d'analyse syntaxique probabiliste



Types d'analyse syntaxique probabiliste

1. Grammaires Hors Contexte Probabilistes (PCFG - Probabilistic Context-Free Grammars)

Les **grammaires hors contexte** (CFG) sont couramment utilisées pour décrire la syntaxe des langages formels.

Lorsqu'on les enrichit avec des probabilités, on obtient des **grammaires hors contexte probabilistes** (PCFG).



Méthodes d'analyse syntaxique probabiliste



Types d'analyse syntaxique probabiliste

Grammaires Hors Contexte Probabilistes (PCFG - Probabilistic Context-Free Grammars)

Une PCFG étend les grammaires hors-contexte en associant une probabilité à chaque règle de production:

$A \rightarrow \beta [p]$

Où:

A est un symbole non-terminal

β est une séquence de symboles (terminaux ou non-terminaux)

p est la probabilité que A se réécrive en β (avec $\sum p = 1$ pour toutes les règles ayant A en partie gauche)



Méthodes d'analyse syntaxique probabiliste



Types d'analyse syntaxique probabiliste

Exemple de grammaires Hors Contexte Probabilistes

Une grammaire hors contexte simple pourrait inclure une règle comme :

$$S \rightarrow NP \ V \ P$$

Cette règle peut être enrichie avec une probabilité telle que :

$$P(S \rightarrow NP \ VP) = 0.7$$

CAD qu'il y a 70% de chances que la phrase soit composée d'un syntagme nominal (NP) suivi d'un syntagme verbal (VP).



Méthodes d'analyse syntaxique probabiliste



Types d'analyse syntaxique probabiliste

2. Grammaires de Dépendance Probabilistes (PDG - Probabilistic Dependency Grammars)

Les **grammaires de dépendance** sont une alternative aux grammaires hors contexte, où l'accent est mis sur les relations de dépendance entre les mots d'une phrase

Les **grammaires de dépendance probabilistes** ajoutent une dimension probabiliste à ces relations, où chaque dépendance entre deux mots est associée à une probabilité.



Méthodes d'analyse syntaxique probabiliste



Types d'analyse syntaxique probabiliste

Exemple de grammaires de Dépendance Probabilistes

Dans une phrase comme "Le chat mange la souris", une grammaire de dépendance probabiliste pourrait spécifier qu'il est 80% probable que "mange" dépende de "chat" et 70% probable que "mange" dépende de "souris".



Méthodes d'analyse syntaxique probabiliste



Types d'analyse syntaxique probabiliste

4. Modèles de Langage Basés sur les Réseaux Neuraux (Deep Learning)

- Avec l'avènement de l'apprentissage profond, les **réseaux neuronaux** ont gagné en popularité pour l'analyse syntaxique probabiliste.
- Les modèles modernes, comme **BERT** ou **GPT**, utilisent des architectures de type Transformer pour apprendre des représentations syntaxiques complexes à partir de données massives.



Méthodes d'analyse syntaxique probabiliste



Types d'analyse syntaxique probabiliste

Modèles de Langage Basés sur les Réseaux Neuraux (Deep Learning)

Ces modèles apprennent non seulement à attribuer des étiquettes grammaticales mais aussi à prédire des structures syntaxiques complexes (par exemple, les relations de dépendance entre les mots), sans nécessiter une grammaire explicite.



Applications de l'Analyse Syntaxique en TLN

Réponse
Automatique
aux Questions

Extraction
d'Information

Traduction
Automatique

Compréhension
des Structures
Syntaxiques des
Phrases

Analyse des
Dépendances
et Structures
Grammaticales

Génération de
Texte

