

# Compilation : introduction et rappels

Arnaud Labourel

**amU** Faculté  
des sciences  
Aix Marseille Université

# Section 1

## Introduction

## Volume horaire


- 5 séances de cours (9h)
- 5 séances de TD (9h)
- 6 séances de 2h de TP en salle machine (12h)

## Évaluation

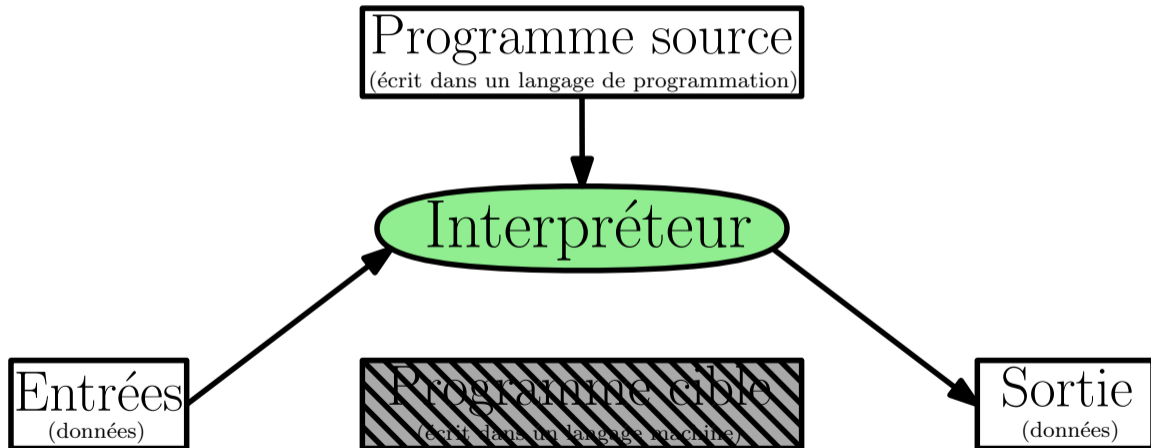
- un examen sur papier (50% de la note)
- un TP noté lors de la dernière séance de TP (25% de la note)
- Contrôle Continu : suivi de TP (25% de la note)

- Qu'est-ce qu'un langage de programmation ?
  - ▶ Un ensemble de notations pour décrire des calculs à des gens et à des machines
  - ▶ Un pont entre les programmeurs et les ordinateurs
- Problème : un ordinateur est généralement incapable d'exécuter directement un programme écrit dans un langage de programmation par un programmeur (langage de programmation haut niveau)
  - Nécessité de traduire les programmes dans une forme compréhensible par l'ordinateur : le rôle d'un compilateur

- Un compilateur est un programme :
  - ① qui lit un programme rédigé dans un langage de programmation, appelé langage source
  - ② et qui le traduit dans un autre langage, le langage cible (généralement en langage machine)
- Le compilateur a aussi pour rôle de reporter l'ensemble des erreurs rencontrées au cours du processus de traduction (non-respect de la grammaire du langage, problèmes de types pour les langages statiquement typé, ...)
- Lorsque le programme cible est un programme exécutable, en langage machine, l'utilisateur peut l'exécuter pour traiter des données et produire des résultats.




- Un interpréteur est un programme :
  - ① qui lit un programme rédigé dans un langage de programmation, appelé langage source
  - ② qui exécute (interprète) directement les instructions du programme
- L'interpréteur doit reporter :
  - ▶ les erreurs de syntaxe (non-respect de la grammaire du langage)
  - ▶ les erreurs détectables qu'à l'exécution (par exemple appel d'une méthode sur une valeur null)
- L'interprétation évite l'étape de compilation, mais est généralement moins efficace lorsque le programme est utilisé de nombreuses fois.





# Compilateur vs interpréteur



## Différences

- L'exécutable produit par un compilateur est souvent plus rapide et efficace que le traitement similaire opéré par un interpréteur.
- Un interpréteur permet d'exécuter plus facilement le code et rend plus facile sa mise à jour.

# Exemple 1 : langage C $\rightarrow$ assembler

```
#include <stdio.h>

int main() {
    int a = 10;
    int b = 20;
    printf("%d\n", a+b);
    return 0;
}
```

```
_main:
    push    rbp
    mov     rbp, rsp
    sub     rsp, 16
    mov     dword ptr [rbp - 4], 0
    mov     dword ptr [rbp - 8], 10
    mov     dword ptr [rbp - 12], 20
    mov     esi, dword ptr [rbp - 8]
    add     esi, dword ptr [rbp - 12]
    lea    rdi, [rip + L_.str]
    mov     al, 0
    call   _printf
    xor     eax, eax
    add     rsp, 16
```

## Exemple 2 langage java → bytecode Java

```
outer:                                0:  iconst_2           22:goto 38
for (int i = 2; i < 1000; i++){      1:  istore_1           25:iinc 2, 1
    for (int j = 2; j < i; j++){      2:  iload_1            28:goto 11
        if (i % j == 0)              3:  sipush 1000        31:getstatic #84;
            continue outer;          6:  if_icmpge 44       34:iload_1
    }                                  9:  iconst_2           35:invokevirtual #85;
    System.out.println (i);          10: istore_2           38:iinc 1, 1
}                                       11: iload_2            41:goto 2
                                       12: iload_1            44:return
                                       13: if_icmpge 31
                                       16: iload_1
                                       17: iload_2
                                       18: irem
                                       19: ifne 25
```

# Compilation

La plupart du temps en compilation, on cherche à traduire

## Programme source


Programme en langage « haut niveau » comme le C, le JAVA, ...

en un

## Programme cible

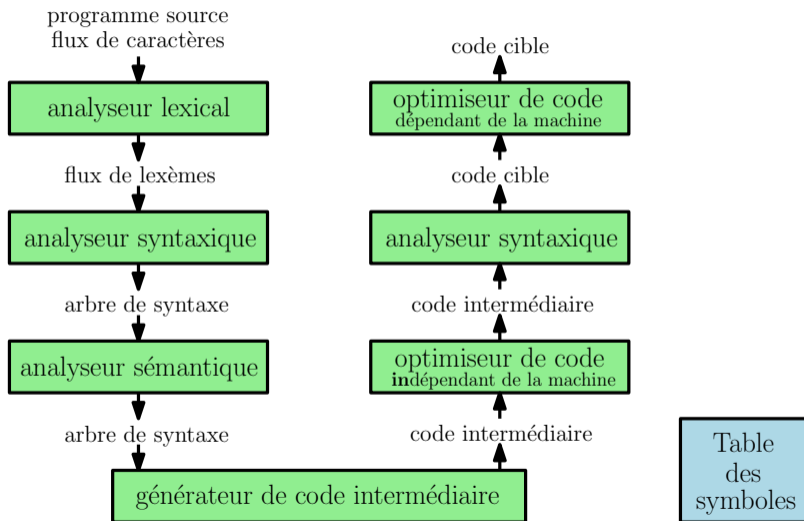
Programme en langage « bas niveau », à savoir un langage assembleur représentant le langage machine de manière lisible par un être humain, comme le bytecode Java, assembler x86, assembler ARM, ...

# Étapes de compilation simplifiées



- 1 une phase d'analyse :
  - ▶ découpe le programme source en parties
  - ▶ détecte d'éventuelles erreurs lexicales
  - ▶ impose une structure grammaticale entre ces constituants
  - ▶ utilise cette structure comme représentation intermédiaire du programme
  - ▶ détecte d'éventuelles erreurs syntaxiques ou sémantiques
  - ▶ collecte et conserve les informations sur les fonctions et variables du programme source dans une structure de données : table des symboles
- 2 une phase de génération qui :
  - ▶ analyse la représentation intermédiaire et la table des symboles
  - ▶ construit le programme cible en fonction

# Étapes de compilation détaillées



L'analyse est composée de 3 parties :

- lexicale
- syntaxique
- sémantique

Dans les compilateurs modernes, il y a souvent un code intermédiaire et deux phases d'optimisation.

Table  
des  
symboles

# Étapes de compilation détaillées

- 1 **Analyse lexicale** : découpage du code en *tokens* (mot-clé, identifiant ou symbole)
- 2 **Analyse syntaxique** : construction de l'arbre de syntaxe issu des règles de la grammaire du langage
- 3 **Analyse sémantique** : création de la table des symboles (noms et types des variables), vérification des types, simplification de l'arbre de syntaxe, ...
- 4 **Génération code intermédiaire** : : code trois-adresse (séquence d'instructions avec au plus 3 opérandes)
- 5 **Optimisation indépendante de la machine (optionnelle)** : par exemple propagation de constante
- 6 **Génération de code** : attribution des registres, ...
- 7 **Optimisation dépendante de la machine (optionnelle)** : utilisation des instructions spécifique du processeur ciblé

## Principe

- Lit un flux de caractères et regroupe les caractères en séquences ayant un sens (identificateur de variable, nombre, opérateur, ...), appelées lexèmes
- Attribue à chaque lexème un *token* de la forme  $\langle \text{nom}, \text{valeur} \rangle$  ou  $\langle \text{nom} \rangle$ , où nom correspond à la nature du lexème et valeur à sa référence dans la table des symboles (pour les variables et fonctions)

Exemple :

- Code :  $p = 60 + y * x$
- Lexèmes :  $p, =, 60, +, y, *, x$
- Tokens :  $\langle \text{var}, 1 \rangle \langle = \rangle \langle 60, \text{int} \rangle \langle + \rangle \langle \text{var}, 3 \rangle \langle * \rangle$   
 $\langle \text{var}, 2 \rangle$

• Tables des symboles :

1	2	3	...
$p$	$x$	$y$	...
...	...	...	...




Crée, à partir des tokens reçus de l'analyseur lexical, une représentation sous forme d'arbre illustrant la structure grammaticale du flux de lexèmes

- Arbre de syntaxe (ou de dérivation)
- Un nœud  $n$  représente un opérateur syntaxique
- Chaque fils de  $n$  représente un opérande de l'opération

# Analyse syntaxique : exemple

- *Tokens* :  $\langle \text{var}, 1 \rangle \langle = \rangle \langle 60, \text{int} \rangle \langle + \rangle \langle \text{var}, 3 \rangle \langle * \rangle \langle \text{var}, 2 \rangle$
- Arbre de dérivation :




- Tables des symboles :

1	2	3	...
<i>p</i>	<i>x</i>	<i>y</i>	...
...	...	...	...

## Principe

- Utilise l'arbre de syntaxe et la table des symboles pour vérifier la cohérence sémantique du code par rapport à la définition du langage (sa grammaire)
- Vérification du typage des opérandes pour chaque opération (retour d'une erreur, changement de type...)



Coercition d'int en float


1	2	3	...
<i>p</i>	<i>x</i>	<i>y</i>	...
float	float	float	...
...	...	...	...

# Génération de code intermédiaire

## Principe

Génération d'une représentation bas niveau du programme source (code intermédiaire facile à produire et facile à traduire en assembleur)

⇒ code à trois adresses généré à partir de l'arbre de syntaxe et de la table des symboles



```
t1 = intToFloat(60)
t2 = var3 * var2
t3 = t1 + t2
var1 = t3
```

## Principe

Amélioration du code intermédiaire pour obtenir un meilleur programme cible (plus efficace/rapide)

```
t1 = intToFloat(60)
t2 = var3 * var2
t3 = t1 + t2
var1 = t3
```

→

```
t1 = var3 * var2
t2 = 60.0 + t1
var1 = t2
```

## Principes

- Registres (zone de mémoire centrale à accès extrêmement rapide  $\sim 1$  ns) réservés pour les variables les plus utilisées
  - Mémoire physique (zone de mémoire à accès rapide  $\sim 100$  ns) réservés pour toutes les autres variables
- ⇒ bien allouer les registres (en nombre très limité) lors de la traduction en assembleur

```
t1 = var3 * var2
```

```
t2 = 60.0 + t1
```


```
var1 = t2
```

```
mov eax, [var3] ; a ← var3  
mov ebx, [var2] ; b ← var2  
mul eax ebx ; a ← a * b  
add eax 60.0 ; a ← a + 60.0  
mov [var1] eax ; var1 ← a
```

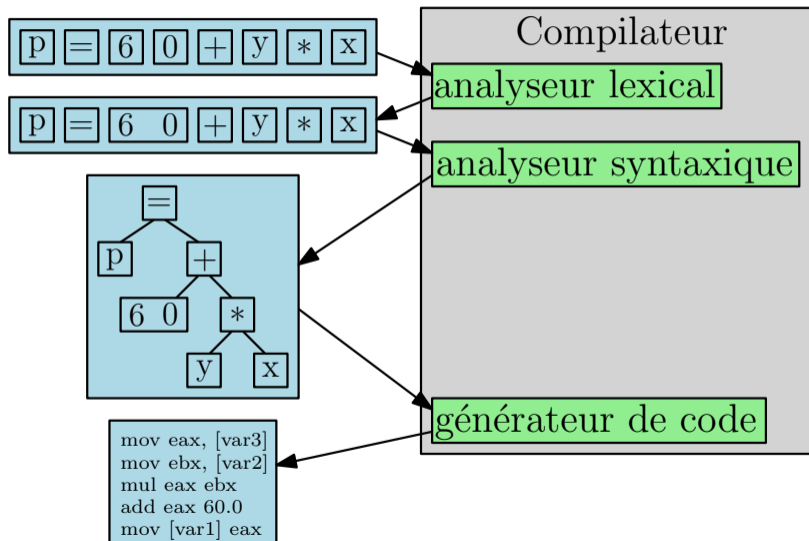
## Résumé

Un **COMPILATEUR** :

- c'est un **VÉRIFICATEUR** et
- c'est un **TRADUCTEUR**



# Étapes principales de compilation





## Section 2

# Théorie des langages : introduction/rappels

# Rappels terminologie langages formels

- Les *symboles* sont des éléments indivisibles qui vont servir de briques de base pour construire des mots.
- Un *alphabet* est un ensemble fini de symboles noté  $\Sigma$ .
- Une suite (finie) de symboles, appartenant à un alphabet  $\Sigma$ , mis bout à bout est appelé un *mot* sur  $\Sigma$ .
- On note  $|m|$  la longueur du mot  $m$  (le nombre de symboles qui le composent) et  $|m|_s$  le nombre de symboles  $s$  que possède le mot  $m$ .

Le mot de longueur zéro est noté  $\varepsilon$ .

- L'ensemble de tous les mots sur un alphabet  $\Sigma$  est noté  $\Sigma^*$ .
- Un *langage* sur un alphabet  $\Sigma$  est un ensemble de mots construits sur  $\Sigma$  et donc une *partie* de  $\Sigma^*$ .

# Exemple de langages

- $\Sigma_1 = \{a\}, L_1 = (\Sigma_1)^* = \{\varepsilon, a, aa, aaa, \dots\}$
- $\Sigma_2 = \{a, b\}, L_2 = \{\varepsilon, ab, aabb, aaabbb, aaaabbbb, \dots\} = \{a^n b^n \mid n \in \mathbb{N}\}$
- $\Sigma_2 = \{a, b\}, L_3 = \{\varepsilon, aa, bb, aaaa, abba, baab, bbbb, \dots\}$   
 $L_3 = \{w_1 w_2 w_3 \dots w_n \mid n \% 2 = 0 \text{ et } \forall 1 \leq i \leq n, w_i = w_{n-i+1}\}$
- $\Sigma_3 = \{a, b, c\}, L_4 = \{\varepsilon, abc, aabbcc, aaabbbccc, \dots\} = \{a^n b^n c^n \mid n \in \mathbb{N}\}$

# Opérations sur les langages

- Union :  $L_1 \cup L_2, \{x \mid x \in L_1 \text{ ou } x \in L_2\}$
- Intersection :  $L_1 \cap L_2, \{x \mid x \in L_1 \text{ et } x \in L_2\}$
- Différence :  $L_1 - L_2, \{x \mid x \in L_1 \text{ et } x \notin L_2\}$
- Complément :  $\bar{L}, \{x \in \Sigma^* \mid x \notin L\}$
- Concaténation :  $L_1 L_2, \{xy \mid x \in L_1 \text{ et } y \in L_2\}$
- Auto concaténation :  $\overbrace{L \dots L}^n, L^n$
- Fermeture de Kleene :  $L^*, \bigcup_{k \geq 0} L^k$

# Comment décrire un langage ?

- **Énumération**

$$L_2 = \{\varepsilon, ab, aabb, aaabbb, aaaabbbb, \dots\}$$

- **Description littéraire**

*Ensemble des mots construits sur l'alphabet  $\{a, b\}$ , commençant par des  $a$  et se terminant par des  $b$  et tel que le nombre de  $a$  et le nombre de  $b$  soit égal*

- **Grammaire de réécriture**

$$G = \langle \{S\}, \{a, b\}, \{S \rightarrow aSb \mid \varepsilon\}, S \rangle$$

# Grammaires de réécriture

Une grammaire de réécriture est un 4-uplet  $\langle N, \Sigma, P, S \rangle$  où :

- $N$  est un ensemble de *symboles non terminaux*, appelé l'*alphabet non-terminal*.
- $\Sigma$  est un ensemble de *symboles terminaux*, appelé l'*alphabet terminal*, tel que  $N$  et  $\Sigma$  soient disjoints.
- $P$  est un ensemble *fini* de *règles de production* ou *règles de réécriture*.

Une règle est de la forme  $\alpha \rightarrow \beta$

- ▶  $\alpha$  est appelé partie gauche de la règle
- ▶  $\beta$  est appelé partie droite de la règle
- ▶  $\alpha$  et  $\beta$  peuvent prendre des formes différentes mais on a toujours :
  - $\alpha \in (N \cup \Sigma)^* N (N \cup \Sigma)^*$
  - $\beta \in (N \cup \Sigma)^*$
- $S$  est un élément de  $N$  appelé l'*axiome* de la grammaire.

Pour alléger les notations, on note:

$$\alpha \rightarrow \beta_1 \mid \beta_2 \mid \dots \mid \beta_n$$

les  $n$  règles :

$$\alpha \rightarrow \beta_1, \alpha \rightarrow \beta_2, \dots, \alpha \rightarrow \beta_n$$

# Quelques exemples de grammaires

- $\langle \{S\}, \{a\}, \{S \rightarrow Sa \mid \varepsilon\}, S \rangle$
- $\langle \{S\}, \{a, b\}, \{S \rightarrow aSb \mid \varepsilon\}, S \rangle$
- $\langle \{S\}, \{a, b\}, \{S \rightarrow aSa \mid bSb \mid aa \mid bb\}, S \rangle$
- $\langle \{S, S_1, S_2\}, \{a, b, c\}, \left\{ \begin{array}{ll} S \rightarrow aS_1c, & S_1 \rightarrow b \mid SS_2, \\ cS_2 \rightarrow S_2c, & bS_2 \rightarrow bb \end{array} \right\}, S \rangle$



# Proto-mots d'une grammaire

Les *proto-mots* d'une grammaire  $G = \langle N, \Sigma, P, S \rangle$  sont des mots construits sur l'alphabet  $\Sigma \cup N$ , on les définit récursivement de la façon suivante :

- $S$  est un proto-mot de  $G$
- si  $\alpha\beta\gamma$  est un proto-mot de  $G$  et  $\beta \rightarrow \delta \in P$  alors  $\alpha\delta\gamma$  est un proto-mot de  $G$ .

Un proto-mot de  $G$  ne contenant aucun symbole non-terminal est appelé un *mot généré* par  $G$ .

Le *langage généré* par  $G$ , noté  $L(G)$  est l'ensemble des mots générés par  $G$ .

# Dérivation

- L'opération qui consiste à générer un proto-mot  $\alpha\delta\gamma$  à partir d'un proto-mot  $\alpha\beta\gamma$  et d'une règle de production  $r$  de la forme  $\beta \rightarrow \delta$  est appelée l'opération de **dérivation**. Elle se note à l'aide d'une double flèche :

$$\alpha\beta\gamma \Rightarrow \alpha\delta\gamma$$

- On note  $\alpha \xRightarrow{k} \beta$  pour indiquer que  $\beta$  se dérive de  $\alpha$  en  $k$  étapes.
- On définit aussi les deux notations  $\xRightarrow{+}$  et  $\xRightarrow{*}$  de la façon suivante :
  - ▶  $\alpha \xRightarrow{+} \beta \equiv \alpha \xRightarrow{k} \beta$  avec  $k > 0$
  - ▶  $\alpha \xRightarrow{*} \beta \equiv \alpha \xRightarrow{k} \beta$  avec  $k \geq 0$

## Attention

Les symboles  $\Rightarrow$  et  $\rightarrow$  ne représentent pas la même chose.

# Conventions pour la définition de grammaire

- Les symboles non terminaux appartenant à  $N$  sont représentés par des lettres latines majuscules :  $A, B, C, S, E, T \dots$
- Les symboles terminaux appartenant à  $\Sigma$  sont représentés par des lettres latines minuscules :  $a, b, c, d \dots$
- Les proto-mots appartenant à  $(N \cup \Sigma)^*$  sont représentés par des lettres grecques minuscules :  $\alpha, \beta, \gamma, \varepsilon \dots$
- L'axiome est représenté par le non-terminal  $S$  et constitue la partie gauche de la première règle de production

# Langage généré par une grammaire

- $L(G)$  est défini de la façon suivante :

$$L(G) = \{m \in \Sigma^* \mid S \xRightarrow{+} m\}$$


- Deux grammaires  $G$  et  $G'$  sont équivalentes si  $L(G) = L(G')$ .

$$G = \langle \{S\}, \{a, b\}, \{S \rightarrow aSb \mid \varepsilon\}, S \rangle$$

$$L_1 = \{\varepsilon, a, aa, aaa, \dots\}$$

$$G = \langle \{S\}, \{a, b\}, \{S \rightarrow Sa \mid \varepsilon\}, S \rangle$$


Sous-ensemble des proto-mots et mots générés de  $G$



$$L_2 = \{\varepsilon, ab, aabb, aaabbb, aaaabbbb, \dots\}$$

$$G = \langle \{S\}, \{a, b\}, \{S \rightarrow aSb \mid \varepsilon\}, S \rangle$$


Sous-ensemble des proto-mots et mots générés de  $G$



$$L_3 = \{aa, bb, aaaa, abba, baab, bbbb, \dots\}$$

$$G = \langle \{S\}, \{a, b\}, \{S \rightarrow aSa \mid bSb \mid aa \mid bb\}, S \rangle$$


Sous-ensemble des proto-mots et mots générés de  $G$



$$L_4 = \{\varepsilon, abc, aabbcc, aaabbbccc, \dots\}$$

$$\langle \{S, S_1, S_2\}, \{a, b, c\}, \left\{ \begin{array}{l} S \rightarrow aS_1c, \quad S_1 \rightarrow b \mid SS_2, \\ cS_2 \rightarrow S_2c, \quad bS_2 \rightarrow bb \end{array} \right\}, S \rangle$$

Sous-ensemble des proto-mots et mots générés de  $G$





# Plusieurs règles peuvent s'appliquer

$$G = \langle \{E, T, F\}, \{+, *, a\}, \{E \rightarrow T + E \mid T, T \rightarrow F * T \mid F, F \rightarrow a\}, E \rangle$$

Les proto-mots générés lors d'une dérivation peuvent comporter plus d'un symbole non-terminal :

$$\begin{aligned} E &\Rightarrow T + E \\ &\Rightarrow T + T \\ &\Rightarrow F + T \\ &\Rightarrow F + F * T \\ &\Rightarrow F + a * T \\ &\Rightarrow F + a * F \\ &\Rightarrow a + a * F \\ &\Rightarrow a + a * a \end{aligned}$$


**Dérivation gauche** : on réécrit le non-terminal le plus à gauche :

$$\begin{aligned} E &\Rightarrow T + E \\ &\Rightarrow F + E \\ &\Rightarrow a + E \\ &\Rightarrow a + T \\ &\Rightarrow a + F * T \\ &\Rightarrow a + a * T \\ &\Rightarrow a + a * F \\ &\Rightarrow a + a * a \end{aligned}$$

**Dérivation droite** : on réécrit le non-terminal le plus à droite :

$$\begin{aligned} E &\Rightarrow T + E \\ &\Rightarrow T + T \\ &\Rightarrow T + F * T \\ &\Rightarrow T + F * F \\ &\Rightarrow T + F * a \\ &\Rightarrow T + a * a \\ &\Rightarrow F + a * a \\ &\Rightarrow a + a * a \end{aligned}$$

# Arbre de dérivation





- Un arbre de dérivation pour  $G$  ( $G = \langle N, \Sigma, P, S \rangle$ ) est un arbre ordonné et étiqueté dont les étiquettes appartiennent à l'ensemble  $N \cup \Sigma \cup \{\varepsilon\}$ .
- Si un nœud de l'arbre est étiqueté par le non-terminal  $A$  et ses fils sont étiquetés  $X_1, X_2, \dots, X_n$  alors la règle  $A \rightarrow X_1, X_2, \dots, X_n$  appartient à  $P$ .
- Un arbre de dérivation indique les règles qui ont été utilisées dans une dérivation, mais pas l'ordre dans lequel elles ont été utilisées.
- À un arbre de dérivation correspondent une seule dérivation droite et une seule dérivation gauche.

# Grammaire ambiguë

Une grammaire  $G$  est *ambiguë* s'il existe au moins un mot  $m$  dans  $L(G)$  auquel correspond plus d'un arbre de dérivation.

Exemple : règles :  $E \rightarrow E + E \mid E * E \mid a$ , mot  $a + a * a$



On évite généralement de travailler sur ce type de grammaire en raison du non-déterminisme induit dans l'analyse.

# Types de règles

Les grammaires peuvent être classées en fonction de la forme de leurs règles de production. On définit cinq types de règles de production :

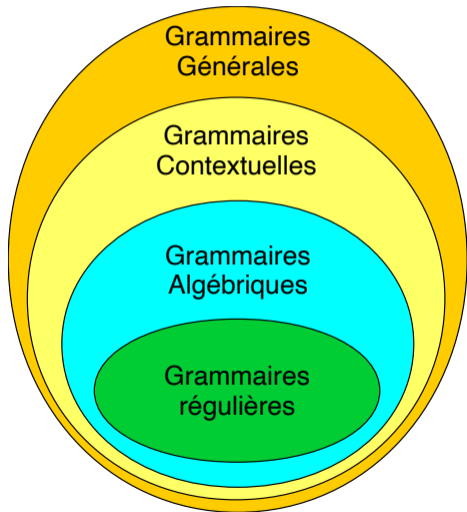
- Règle est *régulière à gauche* si et seulement si  $A \rightarrow xB$  ou  $A \rightarrow x$  ou  $A \rightarrow \varepsilon$  avec  $A, B \in N$  et  $x \in \Sigma$ .
- Règle *régulière à droite* si et seulement si  $A \rightarrow Bx$  ou  $A \rightarrow x$  ou  $A \rightarrow \varepsilon$  avec  $A, B \in N$  et  $x \in \Sigma$ .
- Règle  $A \rightarrow \alpha$  est *hors-contexte* si et seulement si  $A \in N$  et  $\alpha \in (N \cup \Sigma)^*$
- Règle  $\alpha \rightarrow \beta$  est *contextuelle* si et seulement si  $\alpha = \gamma A \delta$  et  $\beta = \gamma B \delta$  avec  $\gamma, \delta, B \in (N \cup \Sigma)^*$  et  $A \in N$ . Le nom “contextuelle” provient du fait que  $A$  se réécrit  $B$  uniquement dans le contexte  $\gamma\_ \delta$ .
- Une règle  $\alpha \rightarrow \beta$  est *sans restriction* si elle n'est pas contextuelle.

# Type d'une grammaire

Une grammaire est :

- **régulière** (de type 3) si elle est régulière à droite ou régulière à gauche. Une grammaire est régulière à gauche si *toutes* ses règles sont régulières à gauche et une grammaire est régulière à droite si *toutes* ses règles sont régulières à droite.
- **hors contexte/algébrique** (de type 2) si toutes ses règles de production sont hors contexte.
- **contextuelle** (de type 1) si toutes ses règles de production sont *contextuelles*.
- **générale** (de type 0) si toutes ses règles de production sont sans restrictions.

# Hiérarchie de Chomsky



# Type d'un langage

Grammaire	Règles	Langage	Machine
3	$A \rightarrow aB, \quad A \rightarrow a$	Régulier/rationnel	automate fini
2	$A \rightarrow \gamma$	Hors contexte/algébrique	automate à pile non-déterministe
1	$\alpha A \beta \rightarrow \alpha \gamma \beta$	Contextuel	Automate linéairement borné
0	$\alpha \rightarrow \beta$	rékursivement énumérable	Machine de Turing



# Exemples de langages réguliers

- $L_1 = \{m \in \{a, b\}^*\}$ ,  $G_1 = \langle \{S\}, \{a, b\}, \{S \rightarrow aS \mid bS \mid \varepsilon\}, S \rangle$

- $L_2 = \{m \in \{a, b\}^* \mid |m|_a \bmod 2 = 0\}$

$$G_2 = \langle \{S, T\}, \{a, b\}, \left\{ \begin{array}{l} S \rightarrow aT \mid bS \mid \varepsilon, \\ T \rightarrow aS \mid bT \end{array} \right\}, S \rangle$$

- $L_3 = \{m \in \{a, b\}^* \mid m = xaaa \text{ avec } x \in \{a, b\}^*\}$

$$G_3 = \langle \{S, T, U\}, \{a, b\}, \left\{ \begin{array}{l} S \rightarrow aS \mid bS \mid aT, \\ T \rightarrow aU, \\ U \rightarrow a \end{array} \right\}, S \rangle$$

- $L_4 = \{m \in \{a, b\}^* \mid |m|_a \bmod 2 = 0 \text{ et } |m|_b \bmod 2 = 0\}$

$$G_4 = \langle \{S, T, U, V\}, \{a, b\}, \left\{ \begin{array}{ll} S \rightarrow aT \mid bU \mid \varepsilon, & T \rightarrow aS \mid bV, \\ V \rightarrow aU \mid bT, & U \rightarrow aV \mid bS \end{array} \right\}, S \rangle$$

# Exemples de langages hors-contexte

- $L_1 = \{a^n b^n \mid n \geq 0\}$

$$G_1 = \langle \{S\}, \{a, b\}, \{S \rightarrow aSb \mid \varepsilon\}, S \rangle$$

- $L_2 = \{mm^{-1} \mid m \in \{a, b\}^*\}$  (langage miroir - palindromes pairs)

$$G_2 = \langle \{S\}, \{a, b\}, \{S \rightarrow aSa \mid bSb \mid \varepsilon\}, S \rangle$$

# Exemples de langages contextuels

$$L_1 = \{a^n b^n c^n \mid n \geq 0\}$$

$$G_1 = \langle \{S, B, \bar{B}, C\}, \{a, b, c\}, \left\{ \begin{array}{ll} S \rightarrow aSBC \mid \varepsilon, & CB \rightarrow \bar{B}B, \\ \bar{B}B \rightarrow \bar{B}C, & \bar{B}C \rightarrow BC, \\ aB \rightarrow ab, & bB \rightarrow bb, \\ bC \rightarrow bc, & cC \rightarrow cc \end{array} \right\}, S \rangle$$