Introduction

CS410 - Langages et Compilation

Julien Henry, Catherine Oriat

Grenoble-INP Esisar

2013-2014

Références

- *Compilation*, Catherine Oriat,
  Année Spéciale Informatique, Grenoble-INP Ensimag

Des questions sur le cours / les TDs ?

`Julien.Henry@imag.fr`

Les cours sont mis en ligne :

`www-verimag.imag.fr/~jhenry/teaching/cs410.html`

Summary

Qu'est ce que la compilation ?

Le développeur écrit un programme dans un langage lisible par l'Homme : C, C++, Java, etc.

La machine fonctionne avec des programmes *exécutables* : dans un langage lisible par l'ordinateur (binaire).

La phase de *compilation* transforme un programme écrit dans un langage "humain" en un programme exécutable par la machine.

Exemples

Vous êtes déjà familiers avec le processus de compilation :

- En langage C : `gcc toto.c -o toto` produit l'exécutable `toto`
- En Java : `javac toto.java` produit `toto.class`

Via un environnement de développement intégré (eclipse, visual studio, etc), l'IDE utilise lui même un compilateur.

Construction d'un langage de programmation

Pour permettre une traduction automatique en langage machine, les langages de programmation sont définis très précisément :

- **Lexicographie** : définit les "mots" autorisés dans le langage.
- **Syntaxe** : définit comment "assembler" ces mots (grammaire).
- **Sémantique** : définit le "sens" de chacunes des constructions du langage.

La **norme**, ou **standard** d'un langage est définie dans un document officiel :

- 552 pages pour C99 : `http://www.open-std.org`
- 879 pages pour C++ : `http://www.open-std.org`
- 670 pages pour Java : `http://docs.oracle.com/javase/specs`

Summary

Compilateur, Interprète

Un *compilateur* est un programme :

- Entrée : un programme P écrit dans le langage L
- Sortie : un programme P' écrit dans le langage L'

P et P' ont la même *sémantique* : pour toute entrée I, la sortie de P et la sortie de P' sont les même.
Exemple :

- un compilateur qui transforme un code C ou C++ en langage d'assemblage (gcc, clang, . . .)
- un compilateur qui transforme un code Java en bytecode Java (javac)

Compilateur, Interprète

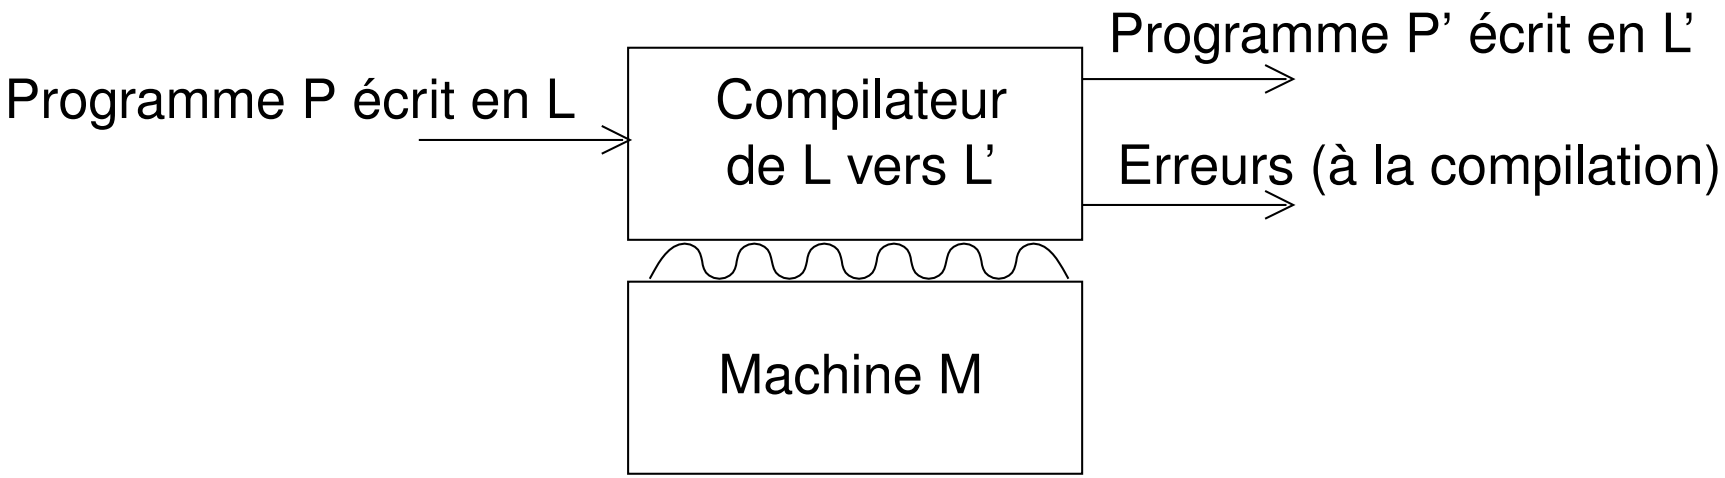

FIGURE: Compilation de P

Compilateur, Interprète

Un *interprète* est un programme :

- Entrée : un programme P écrit dans le langage L des données d'entrée I
- Sortie : le résultat de l'exécution de P avec les entrées I

Exemple : interprète de machine virtuelle Java, qui prend en entrée un programme en bytecode Java et ses entrées, et l'exécute.

Compilateur, Interprète

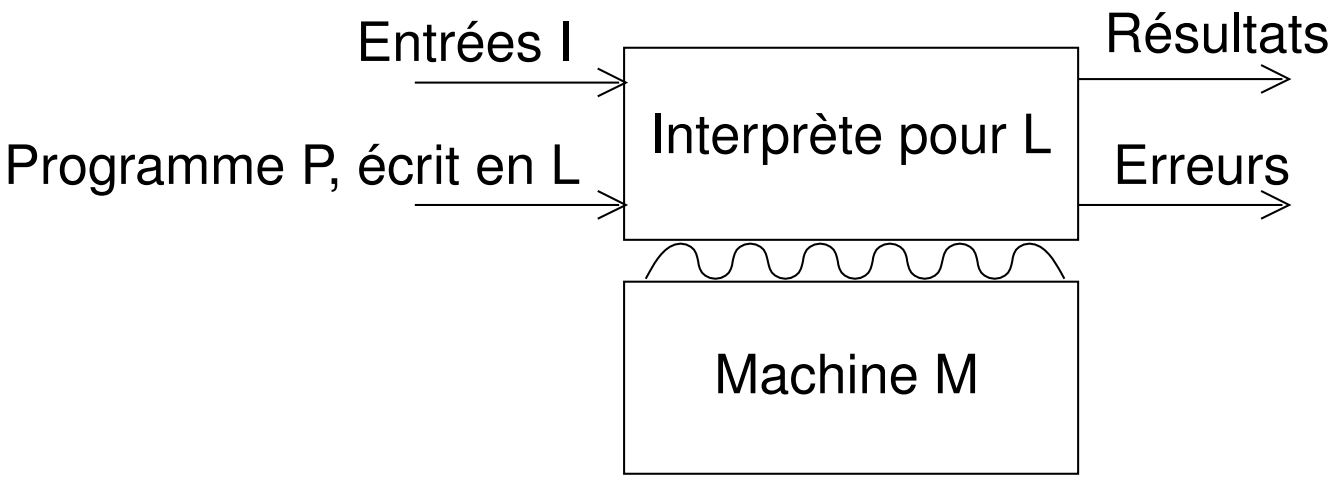

FIGURE: Interprétation de P avec les entrées I

Langages "Mixtes"

Certains langages sont à mi-chemin entre interprétation et compilation (ex : Java).

- Ils sont compilés en une représentation compacte non exécutable (ex : bytecode Java)
- Cette représentation est ensuite interprétée par une machine virtuelle

Rôle du compilateur

Pas seulement transformer un programme d'un langage vers un autre.
Mais aussi :

- Vérifier des propriétés sur le programme
- Lever des erreurs
- Optimiser le code

Propriétés statiques / dynamiques

- *statique* : propriété qui peut être déterminée lors de la phase de compilation, vraie pour toutes les exécutions possibles du programme.
- *dynamique* : propriété qui concerne uniquement une exécution donnée.

Propriétés statiques / dynamiques

- *statique* : propriété qui peut être déterminée lors de la phase de compilation, vraie pour toutes les exécutions possibles du programme.
- *dynamique* : propriété qui concerne uniquement une exécution donnée.

Exemple : en Java, l'expression $b * b - 4.0 * a * c$

Propriétés statiques / dynamiques

- *statique* : propriété qui peut être déterminée lors de la phase de compilation, vraie pour toutes les exécutions possibles du programme.
- *dynamique* : propriété qui concerne uniquement une exécution donnée.

Exemple : en Java, l'expression $b * b - 4.0 * a * c$

- Propriété statique : son typage
- Propriété dynamique : son signe, sa valeur, etc.

Erreurs d'un programme

Plusieurs types d'erreurs :

- erreurs statiques :
  - Erreurs lexicales : utilisation de caractères incorrect, etc.
  - Erreurs de syntaxes : oubli d'un ' ;', mauvaise disposition de '(' ou '{', etc.
  - Erreurs de contexte : utilisation d'une variable non déclarée, erreur de typage, etc.
- erreurs dynamiques : débordement d'une opération arithmétique, déréférencement de pointeur nul, ...

Le compilateur détecte les erreurs statiques.

Ce que l'on attend d'un compilateur

1. Efficacité :
   - le compilateur doit si possible être rapide.
   - il doit produire un code qui s'exécutera rapidement.
2. Correction : le programme original et le programme compilé doivent avoir la même sémantique.

Summary

Structure du compilateur

2 phases :

1. Analyse :
   - construction d'une représentation structurée du programme
   - vérification des propriétés statiques
2. Synthèse :
   - traduction de la représentation interne vers le langage cible

Représentation Intermédiaire : Arbre Abstrait

```
val = val + 1;
```

programme, sous forme d'une suite de caractères

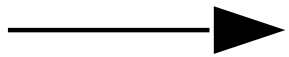

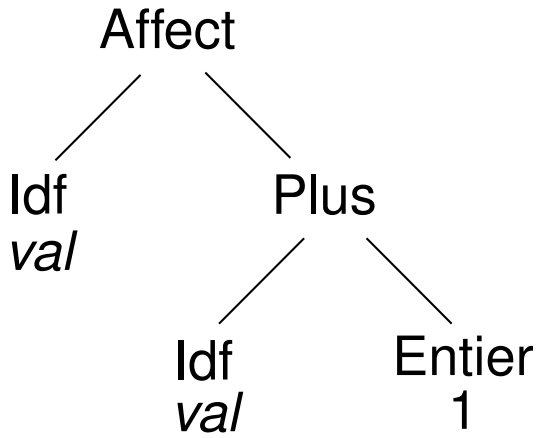

Arbre abstrait du programme

```
val = val + 1
```

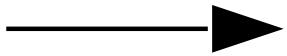

Erreur de syntaxe

FIGURE: Construction de l'arbre abstrait

Analyse

Le programme à compiler est une suite de caractères.

- Analyse lexicale : parcours la suite de caractères et en extrait les unités lexicales (mots).
  Soulève les *erreurs lexicales*.
- Analyse syntaxique : vérifie que la suite de mots vérifie bien la grammaire du langage, et construit une représentation interne et structurée du programme (*Arbre Abstrait*).
  Soulève les *erreurs syntaxiques*.
- Analyse contextuelle : vérifie que le programme vérifie certaines propriétés statiques. Décore l'arbre abstrait avec des informations utiles pour l'optimisation / la génération du code cible.
  Soulève les *erreurs contextuelles*.

Synthèse

Génération de Code : Génère un programme dans le langage cible, à partir de l'arbre abstrait décoré et optimisé.

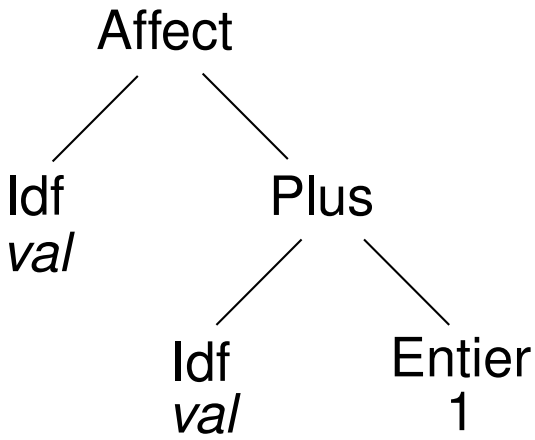

Arbre abstrait du programme

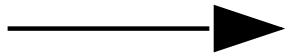

```
LOAD #1, R0
ADD @val, R0
STORE R0, @val
```

`@val` : adresse de l'objet val
`LOAD` : chargement dans un registre
`STORE` : chargement à une adresse

FIGURE: Synthèse

Optimisations

Des optimisations du code peuvent avoir lieu à différentes étapes :

- Optimisation sur l'arbre abstrait
- Optimisation du code généré

Structure Modulaire

Les compilateurs modernes sont concus de manière à pouvoir compiler plusieurs langages dans plusieurs langages cible.

- Front-End : un Front-end par langage soure
  - analyse lexicale et syntaxique
  - construction d'une représentation intermédiaire
- "Coeur" : unique
  - analyse sémantique et optimisation sur la représentation intermédiaire (AST)
- Back-End : un Back-end par langage cible
  - sélection d'instructions
  - génération du code cible

Objectifs et Intérêts du cours

1. Maîtriser les langages de programmation
   - vérifications
   - transformations du compilateurs
2. Savoir concevoir un langage
3. Avoir les outils théoriques pour écrire un compilateur

Application : Projet en parallèle.

Outils théoriques

Théorie des langages, en particulier :

1. langages réguliers : pour décrire la lexicographie des langages de programmation.
2. grammaires hors-contexte : pour décrire la syntaxe des langages de programmation.
3. grammaires attribuées : pour faire des vérifications contextuelles sur le programme.