Partie I : Vue d'ensemble et bases

- Pourquoi étudier la construction de compilateurs ?
- Le rôle et la structure d'un compilateur.
- Langage et syntaxe.
- Langages formels.

Pourquoi étudier la construction de compilateurs ?

Très peu de gens écrivent des compilateurs comme profession.

Alors pourquoi apprendre à construire des compilateurs ?

- Un informaticien compétent comprend les langages de haut niveau ainsi que le matériel.
- Un compilateur relie les deux.
- C'est pourquoi comprendre les techniques de compilation est essentiel pour comprendre comment les langages de programmation et les ordinateurs interagissent.
- Beaucoup d'applications contiennent de petits langages pour leur configuration et pour flexibiliser leur contrôle.
  - Exemples : les macros de Word, les scripts pour le graphisme et l'animation, les descriptions de structures de données.

Pourquoi étudier la construction de compilateurs ? (suite)

- Les techniques de compilation sont nécessaires pour correctement implanter ces langages d'extension.
- Les formats de données sont aussi des langages formels. De plus en plus de données en format interchangeable ressemblent à un texte d'un langage formel (p.ex. HTML, XML).
- Les techniques de compilation sont utiles pour lire, manipuler et écrire des données.
- Mis à part cela, les compilateurs sont d'excellents exemples de grands systèmes complexes
  - qui peuvent être spécifiés rigoureusement,
  - qui peuvent être réalisés seulement en combinant théorie et pratique.

Le rôle d'un compilateur

- Le rôle principal d'un compilateur est de traduire des programmes écrits dans un langage *source* donné en un langage *objet*.
- Souvent, le langage source est un langage de programmation et le langage objet est un langage machine.
- Quelques exceptions : traduction source-source, traduction de code machine, manipulation de données en XML.
- Une partie du travail du compilateur est aussi de détecter si un programme donné est conforme aux règles du langage source.
- Une spécification d'un compilateur est constituée par
  - une spécification de son langage source et de son langage objet,
  - une spécification du processus de traduction de l'un en l'autre.

Langages

- Formellement, un langage est un ensemble de *chaînes de caractères* que l'on appelle les *phrases* du langage.
- En pratique, chaque phrase possède une *structure* qui peut être décrite par un *arbre.*
- Les règles régissant la structure des phrases sont définies par une *grammaire*.
- Exemples :
  - Les phrases d'un langage de programmation sont des programmes (légaux).
  - Un programme est une phrase constituée de mots (ou : *symboles, lexèmes*); sa structure est donnée par une grammaire.
  - Un mot est lui-même une séquence de caractères dont la structure peut aussi être donnée par une grammaire.

Structure d'un compilateur

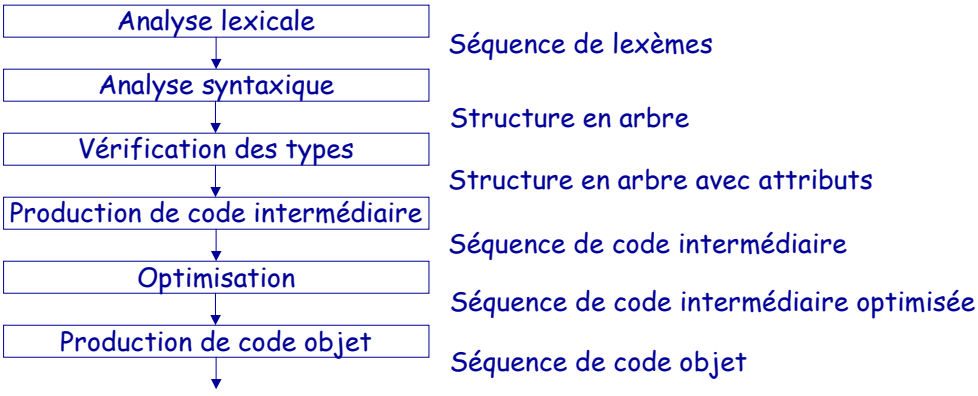

- Les phases ne sont pas nécessairement exécutées l'une après l'autre.
- Les structures de données intermédiaires n'existent parfois jamais dans leur intégralité.

Langage et syntaxe

- Les phrases d'un langage ont une structure déterminée par une grammaire.
- **Exemple**: Une phrase correcte est formée par un sujet suivi d'un verbe.
- Ceci peut être exprimé par une grammaire :

  Phrase = Sujet Verbe
- Complétons cela avec deux nouvelles *productions* :

  Sujet = "Pierre" | "Claire"

  Verbe = "cours" | "marche"
- Ceci définit 4 phrases possibles :

  Pierre cours | Pierre marche | Claire cours | Claire marche
- Généralement, les langages contiennent un nombre infini de phrases.

Langage et syntaxe (suite)

- Un nombre infini de phrases peuvent être exprimées par un nombre fini de productions en définissant certains symboles récursivement.
- Exemple :

  Nombre = Chiffre | Chiffre Nombre

  Chiffre = "0" | "1" | "2" | "3" | "4" | . . . | "9".

Génère :

0
12
123
1024

etc.

Langages formels

Une grammaire est formellement définie par :

- Un ensemble de *symboles terminaux.*
- Un ensemble de *symboles non-terminaux*
- Un ensemble de *règles syntaxiques* (ou : *productions*)
- Un *symbole initial.*

Une grammaire définit un langage formé par l'ensemble des séquences finies de symboles terminaux qui peuvent être dérivées du symbole initial par des applications successives des productions.

Le langage des grammaires (non contextuelles)

```
grammar     = production grammar  |  (empty)
production  = identifier "=" expression "."
expression  = term  |  expression "|" term
term        = factor  |  term factor  |  "(empty)"
factor      = identifier  |  string
identifier  = letter  |  identifier letter  |  identifier digit
string      = "\"" stringchars "\""
stringchars = stringchars stringchar  |  (empty)
stringchar  = escapechar  |  plainchar
escapechar  = "\\" char
plainchar   = charNoQuoteNoEscape
char        = «any printable character».
charNoQuoteNoEscape = «any printable character except `"' and `\'.»
```

Le langage des grammaires (non contextuelles) (suite)

- Il a été développé à l'origine par J. Backus et P. Naur pour la définition d'Algol 60.
- C'est pourquoi on l'appelle la *notation Backus-Naur* ou *BNF* (de l'anglais *Backus-Naur form*).
- Exercice : Déterminez le symbole initial, et les symboles terminaux et non-terminaux de cette grammaire.

Notation Backus-Naur étendue

Les grammaires peuvent souvent être simplifiées et raccourcies en utilisant deux constructions supplémentaires :

- {x} exprime la *répétition :* zéro, une ou plusieurs occurrences de x.
- [x] exprime l'*option :* zéro ou une occurrence de x.

Ce nouveau formalisme est appelé *notation Backus-Naur étendue* ou *EBNF* (de l'anglais *extended Backus-Naur form*). Sa syntaxe est la suivante:

Notation Backus-Naur étendue (suite)

```
syntax      =  {production}
production  =  identifier "=" expression "."
expression  =  term {"|" term}
term        =  {factor}
factor      =  identifier
            |  string
            |  "(" expression ")"
            |  "[" expression "]"
            |  "{" expression "}"
identifier  =  letter { letter  |  digit }
string      =  "\"" {stringchar} "\"
```

(le reste est identique au BNF)

Exercice : Écrivez la grammaire des nombres entiers (éventuellement signés) en BNF puis EBNF.