Partie IV : Syntaxe abstraite

- Actions sémantiques
- Syntaxe abstraite
- Arbres de syntaxe abstraite
- Accéder aux arbres
- OO
- Décomposition orientée objet
- Visiteurs

Actions sémantiques

- Un analyseur syntaxique fait généralement plus que simplement reconnaître une syntaxe.
- Il peut :
  - Évaluer du code (interpréteur)
  - Émettre du code (compilateur simple passe)
  - Construire une structure de données interne (compilateur multi-passes)
- De façon générale, un analyseur syntaxique réalise des *actions sémantiques.*
- Dans un analyseur à descente récursive, les actions sémantiques sont intégrées aux routines de reconnaissance.
- Dans un analyseur ascendant généré par une machine, elles sont ajoutées à la grammaire soumise au générateur d'analyseurs.

Un analyseur / interpréteur

Le langage source : les expressions arithmétiques.

E = E "+" T | E "-" T | T
T = T "*" F | T "/" F | F
F = number | "(" E ")"

Le langage source dans une formulation LL(1) :

Le programme du simple analyseur

```
package calc;

import java.io.*;

class Parser extends Scanner {

  public Parser(InputStream in) {
    super(in);
    nextToken();
  }

  public void expression() {
    term();
    while (token == PLUS ||
           token == MINUS) {
      nextToken();
      term();
    }
  }

  public void term() {
    factor ();
    while (token == MUL ||
           token == DIV){
      nextToken();
      factor();
    }
  }

  public void factor() {
    if (token == NUMBER) {
      nextToken();
    } else if (token == LPAREN) {
      nextToken();
      expression();
      if (token == RPAREN)
        nextToken();
      else error ("')' expected");
    } else
       error ("illegal start of " +
              "expression");
  }
}
```

L'interpréteur

```
package calc;

import java.io.*;

class Parser extends Scanner {

  public Parser(InputStream in) {
    super(in);
    nextToken();
  }

  public int expression () {
    int v = term();
    while (token == PLUS ||
           token == MINUS) {
      int operator = sym;
      nextToken();
      int v2 = term();
      if (operator==PLUS) v = v + v2;
      else v = v - v2;
    }
    return v;
  }

  public int term() {
    int v = factor();
    while (token == MUL ||
           token == DIV) {
      int operator = sym;
      nextToken();
      int v2 = factor();
      if (operator==MUL) v = v * v2;
      else v = v / v2;
    }
    return v;
  }

  public int factor () {
    int v = 0;
    if (token == NUMBER) {
      v = Integer.parseInt(chars);
      nextToken();
    } else if (token == LPAREN) {
      nextToken();
      v = expression();
      if (token == RPAREN)
        nextToken();
      else error ("')' expected");
    } else
      error ("illegal start of " +
             "expression");
    return v;
  }
}
```


Arbres syntaxiques

- Dans un compilateur multi-passes, l'analyseur construit explicitement un arbre syntaxique.
- Toutes les phases suivantes du compilateur travaillent sur l'arbre de syntaxe abstraite, et non sur le programme source.
- Cet arbre peut être l'arbre de syntaxe concrète correspondant à la grammaire non contextuelle.
- Mais on utilise généralement une forme simplifiée.

Syntaxe abstraite contre syntaxe concrète

Concernant l'arbre de syntaxe concrète, quelques simplifications sont possibles :

1. Pas besoin d'analyser un texte dans le langage abstrait, donc ( ) pas nécessaires.

```
A * (B + C)     devient ...
```

2. Pas besoin de maintenir les symboles terminaux.

```
If (x == 0) y = 1 else y = 2   devient ...
```


Arbres de syntaxe abstraite

- Un arbre de syntaxe abstraite est un arbre avec un type de nœud pour chaque alternative dans la syntaxe abstraite.
- On représente un arbre en utilisant un ensemble de classes Java, une pour chaque alternative.
- Une super-classe abstraite commune : Tree.
- Chaque classe représente les sous-arbres comme variables d'instances.
- Chaque classe a un constructeur pour construire un nœud du type donné.

Arbre de syntaxe abstraite (2)

- Exemple : Pour les expressions arithmétiques :

```
abstract class Tree {
  static class NumLit extends Tree {
    int value;
    ...
  }
  static class Operation extends Tree {
    int operator;
    Tree left, right;
    ...
  }
}
```


Accéder aux arbres

- Les arbres de syntaxe abstraite constituent la structure de données d'entrée centrale des phases suivantes du compilateur.
- ⇒ Important de trouver une représentation qui puisse être utilisée de manière flexible.
- Comment les processeurs d'arbres accèdent-ils à cet arbre ?
- Une solution simple (et grossière); utiliser `instanceof` pour trouver le type du nœud syntaxique, puis le convertir pour accéder aux éléments de l' arbre, p.ex.

```
if (tree instanceof NumLit) {
  return ((NumLit)tree).value;
}
```

- Mais ceci n'est ni élégant ni efficace.
- Une meilleure solution : une décomposition orientée objet.
- Une solution encore meilleure : les *visiteurs*

Exemple : Les expressions arithmétiques

- Nous allons présenter maintenant à la fois la décomposition orientée objet et l'accès par visiteur en utilisant l'exemple des expressions arithmétiques.
- Deux types de nœuds : `Operation`, `NumLit`.
- Deux types d'actions : `eval`, `toString`.
- Un exemple très simple.
- Typiquement les langages ont 20 (Misc), 40 (Java), ou plus types de nœuds.
- Un compilateur typique a 5 - 10 processeurs.
- Mais il n'y a qu'une différence d'échelle – la structure de base reste la même.

Structure des classes

```
package calc;

public abstract class Tree {
  int pos; // position pour signaler
           // les erreurs, présente
           // dans tous les noeuds.

  /** une sous-classe pour
      représenter les nombres */

  static class NumLit extends Tree {

    int value;

    NumLit(int pos, int value) {
      this.pos = pos;
      this.value = value;
    }
  }

  /** une sous-classe pour
    représenter les opérations */

  static class Operation extends Tree {

    int operator;
    Tree left, right;

    Operation (int pos, int operator,
               Tree left, Tree right)
    {
      this.pos = pos;
      this.operator = operator;
      this.left = left;
      this.right = right;
    }
  }
}
```

Un analyseur qui construit un arbre

```
package calc;
import java.io.*;
import calc.Tree.*;

class Parser extends Scanner {

  public Parser(InputStream in) {
    super(in);
    nextToken();
  }

  public Tree expression() {
    Tree t = term();
    while (token == PLUS ||
           token == MINUS) {
      int startpos = pos;
      int operator = sym;
      nextToken();
      t = new Operation (startpos,
        operator, t, term());
    }
    return t;
  }

  public Tree term() {
    Tree t = factor();
    while (token == MUL ||
           token = DIV) {
      int startpos = pos;
      int operator = sym;
      nextToken();
      t = new Operation (startpos,
        operator, t, factor());
      }
      return t;
    }

    public Tree factor() {
      Tree t = null;
      if (token == NUMBER) {
        t = new NumLit (pos,
          Integer.parseInt (chars));
        nextToken();
      } else if (token == LPAREN) {
        nextToken();
        t = expression();
        if (token == RPAREN)
          nextToken();
        else error ("')' expected");
      } else
        error("illegal start of " +
              "expression");
      return t;
    }
  }
```


Décomposition orientée objet

- Chaque processeur d'arbre P est représenté par une méthode dynamique P() dans chaque classe d'arbre.
- La méthode est abstraite dans la classe Tree, et implémentée dans chaque sous-classe.
- Pour traiter un sous-arbre, il suffit d'appeler sa méthode correspondant au processeur : `t.P()`.
- Dans notre exemple : définir les méthodes `eval` et `toString` dans les classes `NumLit` et `Operation`.
- Les méthodes `eval` et `toString` sont abstraites dans la classe Tree, donc elles peuvent être invoquées sur chaque arbre.
- Ce qu'elles font va dépendre du type concret de l'arbre.

Décomposition OO pour les expressions

(on a omis les constructeurs)

```
package calc;

public abstract class Tree {
  int pos;

  public abstract String toString();
  public abstract int eval();

  static class NumLit extends Tree {
    int value;

    public String toString() {
      return String.valueOf(value);
    }

    public int eval() {
      return value;
    }
  }

 static class Operation extends Tree{
    int operator;
    Tree left, right;

    public String toString() {
      return "("+ left.toString() +
        Scanner.representation(
          operator) +
        right.toString() + ")";
    }

    public int eval() {
      int l = left.eval();
      int r = right.eval();
      switch (operator) {
        case Scanner.PLUS:
          return l + r;
        case Scanner.MINUS:
          return l - r;
        case Scanner.MUL:
          return l * r;
        case Scanner.DIV:
          return l / r;
        default:
          throw new InternalError();
      }
    }
  }
}
```


Une classe « pilote »

```
package calc;
class Main {
   static public void main(String[] args) {
     System.out.print("> ");
     Tree t = new Parser(System.in).expression();
     if (t != null)
       System.out.println(t.toString() + " evaluates
            to " + t.eval());
   }
}
```

- Utilisation :

```
java calc.Main
> 2 * (3 + 4);
(2'*'(3'+'4)) evaluates to 14
```

Extensibilité

- Avec un arbre de syntaxe abstraite, il peut y avoir extension dans deux dimensions.
  - Ajouter un nouveau type de nœud .
  - Ajouter un nouveau type de méthode de traitement.
- Quelle est la plus commune ?
- Quelle est la plus facile à réaliser ?
- Ajouter un nouveau type de nœud : ajouter une nouvelle sous-classe
- Ajouter une nouvelle méthode de traitement : ajouter des méthodes de traitement à chaque sous-classe.

Visiteurs

- Le motif de conception (*design pattern*) "visiteur" permet une extension simple par de nouveaux traitements.
- Toutes les méthodes d'un traitement sont regroupées dans un objet visiteur

  $\Rightarrow$ facile de partager du code et des données communes
- Un objet visiteur contient pour chaque type `K` d'arbre une méthode (appelée `caseK`) qui peut traiter les arbres de ce type.
- L'arbre contient uniquement une méthode de traitement générique qui ne fait qu'appliquer un objet visiteur donné.

Arbres visitables pour les expressions

(on a omis les constructeurs)

```
package calc;
abstract class Tree {
  int pos;
  abstract void apply(Visitor v);
  static class NumLit extends Tree {
    int value;
    void apply(Visitor v) { v.caseNumLit(this); }
  }
  static class Operation extends Tree {
    int operator; Tree left, right;
    void apply(Visitor v) { v.caseOperation(this); }
  }
}
interface Visitor {
  void caseNumLit(Tree.NumLit tree);
  void caseOperation(Tree.Operation tree);
}
```


Un visiteur ToString

```
package calc;
import calc.Tree.*;
class ToString implements Visitor {
  String result;
  public void caseNumLit(NumLit tree) {
    result = String.valueOf(tree.value);
  }
  public void caseOperation(Operation tree) {
    result = "(" + visit(tree.left) +
      Scanner.representation(tree.operator) +
      visit(tree.right) + ")";
  }
  public static String visit(Tree tree) {
    ToString v = new ToString();
    tree.apply(v);
    return v.result;
  }
}
```

Un visiteur qui évalue

```
package calc;

import calc.Tree.*;

class Eval implements Visitor {
  int result;

  public void caseNumLit(NumLit tree){
    result = tree.value;
  }

  public void caseOperation(
    Operation tree) {
    int l = visit(tree.left);
    int r = visit(tree.right);

    switch (tree.operator) {

    case Scanner.PLUS :
      result = l + r; break;

    case Scanner.MINUS:
      result = l - r; break;

    case Scanner.MUL:
      result = l * r; break;

    case Scanner.DIV:
      result = l / r; break;

    default:
      throw new InternalError();
    }
  }

  public static int visit(Tree tree){
    Eval v = new Eval();
    tree.apply(v);
    return v.result;
  }
}
```


Classe pilote pour les visiteurs

```
package calc;

class Main {

  public static void main(String[] args) {
    System.out.print("> ");
    Tree t = new Parser(System.in).expression();
    if (t != null)
      System.out.println(ToString.visit(t) + " evaluates to "
                         + Eval.visit(t));
  }
}
```

Quelle est la meilleure solution ?

- Extensibilité
  - La décomposition OO facilite l'ajout de nouveaux types de nœud.
  - Les visiteurs facilitent l'ajout de nouveaux traitements.
- Modularité
  - La décomposition OO permet le partage de données et de code dans un nœud de l'arbre entre les phases.
  - Les visiteurs permettent le partage de données et de code entre les méthodes d'un même traitement.
- Qu'est-ce qui est le plus important ?

Les arbres dans d'autres contextes

- Les arbres avec plusieurs types de nœuds n'interviennent pas que dans la compilation.
- On les retrouve aussi dans la mise en page de texte, dans les documents structurés tels que HTML ou XML, les interfaces graphiques utilisateur (*graphical user interface*).
- Exemple : Composants d'une GUI
- Quelle méthode d'accès à l'arbre est utilisée pour les composants d'une GUI ?
- Quel type d'extension est la plus commune ?

Extensibilité

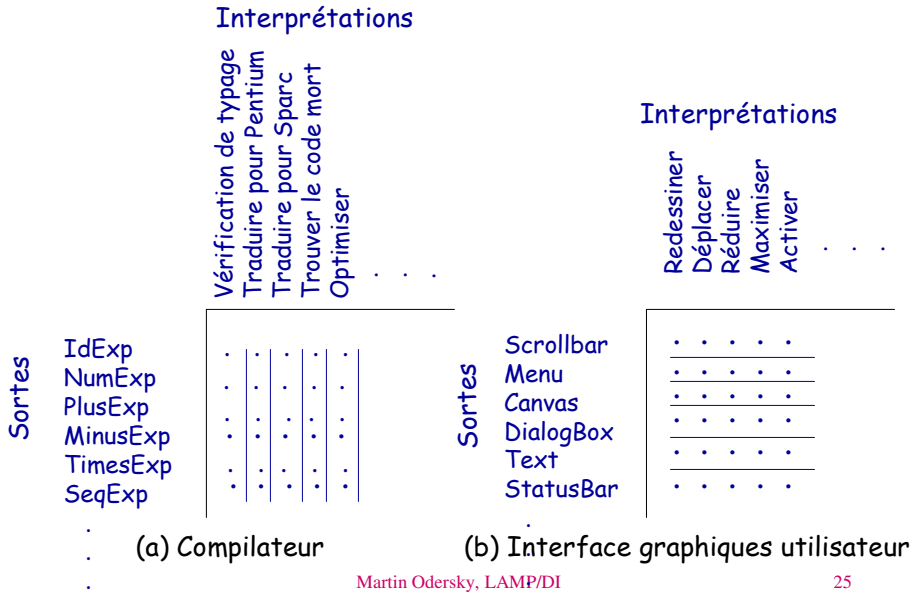

(a) Compilateur (b) Interface graphiques utilisateur

Syntaxe abstraite pour misc

```
P = Program { D } B

B = Body { S } E

D = FunDef ident { F } T E

F = Formal ident T

T = BasicType U
  | ListType T
  | FunType { T } T

U = Unit
  | Any
  | Int

S = VarDef F E
  | While E E
  | Exec E

E = If E E E
  | Assign ident E
  | Binop O E E
  | Listop L E
  | Ident ident
  | UnitLit
  | IntLit int
  | NilLit
  | Apply E { E }
  | B

O = Add | Sub | Mul | Div
  | Mod | Eq  | Ne  | Lt | Le
  | Gt  | Ge  | Cons

L = Head | Tail | IsEmpty
```

De la syntaxe abstraite aux arbres de syntaxe abstraite

- Simplifier encore plus en fusionnant **P**, **D**, **F**, **T**, **S** et **E**

```
Tree = Program { Tree } Tree
     | FunDef String { Tree } Tree Tree
     | Body { Tree } Tree
     | Formal String Tree
     | BasicType int
     | ListType Tree
     | ...
```

- Définir une classe abstraite `Tree` avec des sous-classes internes concrètes `Program`, `FunDef`, `Formal`, `BasicType`, etc.
- Définir une interface visiteur avec les méthodes

```
caseProgram(Program tree)
caseFunDecl(FunDef tree)
...
```


La classe Tree pour misc

```
package miscc;

public abstract class Tree {

  // common for all trees
  int pos;

  abstract void apply(Visitor v);

  static class Program extends Tree {
    Tree[] funs;
    Tree body;

    Program(int pos,
            Tree[] funs, Tree body) {
      this.pos = pos;
      this.funs = funs;
      this.body = body;
    }

    public void apply(Visitor v) {
      v.caseProgram(this);
    }
  }

  static class Formal extends Tree {
      String name;
      Tree tpe;

      Formal(int pos,
             String name, Tree tpe) {
        this.pos = pos;
        this.name = name;
        this.tpe = tpe;
      }

      public void apply(Visitor v) {
        v.caseVarDecl(this);
      }
    }

    ...
  }

  public interface Visitor {
    void caseProgram(Tree.Program tree);
    void caseFormal(Tree.Formal tree);
    ...
  }
```

Explications

- Chaque classe a un constructeur pour construire un nœud du type donné et une méthode `apply` qui applique un visiteur.
- La répétition est exprimée par des tableaux. {T} dans la syntaxe devient `T[]` dans l'arbre.
- Les symboles terminaux sont représentés par leur information essentielle :
  - pour un `ident` : le nom de l'identificateur (`String`).
  - pour un nombre : sa valeur (`int`).
- Le champ `pos` contient la position courante dans l'arbre, importante pour les messages d'erreur. Ce champ est commun à tous les types d'arbres ; c'est pourquoi il est un membre de la classe `Tree`.

Construction de l'arbre

```
package miscc;

import java.util.List;
import java.util.LinkedList;
import miscc.Tree.*;

class Parser extends Scanner {

  ...

  Tree formal() {
    int start = pos;
    String name = chars;
    accept(IDENT);
    accept(COLON);
    Tree type = type();
    return
      new Formal(start, name, type);
  }
```

```
Tree program() {
  int start = pos;

  List list = new LinkedList();
  while (token == DEF) {
    list.add(declaration());
    accept(SEMICOLON);
  }

  Tree body = body();
  Tree[] funs =
    (Tree[])list.toArray(
      new Tree[list.size()]);

  accept(EOF);

  return
    new Program(start, funs, body);
}

...
```

Exemple de visiteur: un formateur d'arbre

```
package miscc;

import miscc.Tree.*;

public class Pretty implements Visitor {
  public void caseProgram(Program tree) {
    for (int i = 0; i < tree.funs; i++) {
      print(tree.funs[i]);
      System.out.println();
    }
    print(tree.body);
  }
  ...
  public void print(Tree tree) {
    tree.apply(this);
  }
}
```