Génération de code

Rémi Forax

Plan

- Code intermédiaire
- Assembleur Java
- Variable local
  - Zone de vie, affectation dans les registres
- Structures de contrôle
  - Max locals/max depth
- Appel de fonction/méthode

Rappel

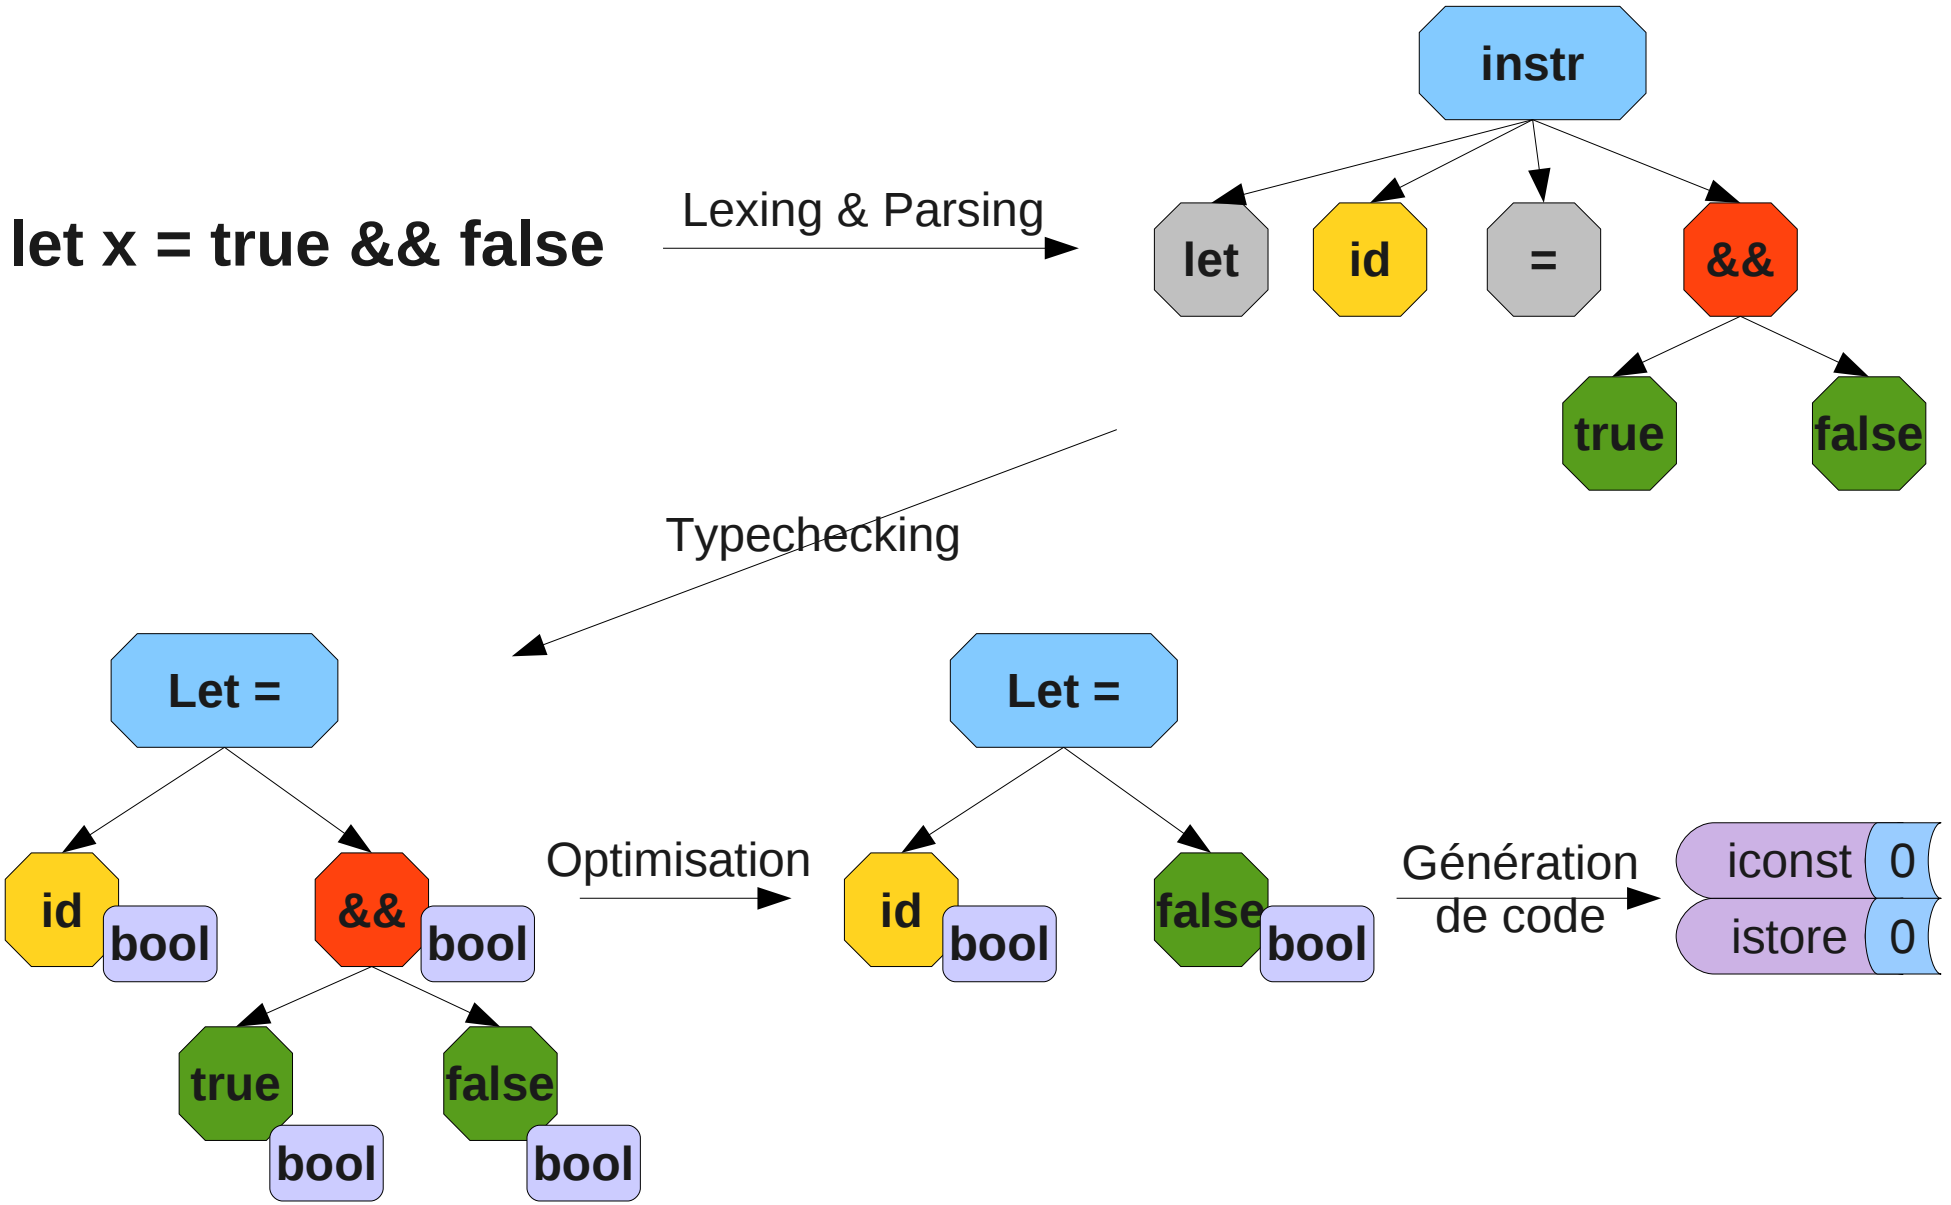
let x = true && false
Lexing & Parsing
instr
let
id
=
&&
true
false
Typechecking
Let =
id
bool
&&
bool
true
bool
false
bool
Optimisation
Let =
id
bool
false
bool
Génération
de code
iconst
0
istore
0

Code intermédiaire

- Code proche de l'assembleur des machines cibles mais pas spécifique à une machine
- Il existe plusieurs sortes de codes intermédiaires

- Caractéristiques communes :
  - Nombre illimité de variables (registres)
  - Instructions de sauts conditionnels ou non pour représenter les tests et boucles

Codes intermédiaires

- Plusieurs sortes de code intermédiaire
  - Code 3 adresses
    - représentation à base de registres
  - Code à base d'arbre,
    - Représentation avec une pile
  - Static Single Assignment form (SSA)
    - 1 variable ne peut être affecté qu'une seul fois
- Dans un vrai compilateur, plusieurs formes peuvent co-exister

Code 3 adresses

- On doit stocker les résultats intermédiaires des expressions dans une variable temporaire

  a = cos(x+2*y)

  devient

  tmp1 = 2*y
  tmp2 = x + tmp1
  a = cos(tmp2)

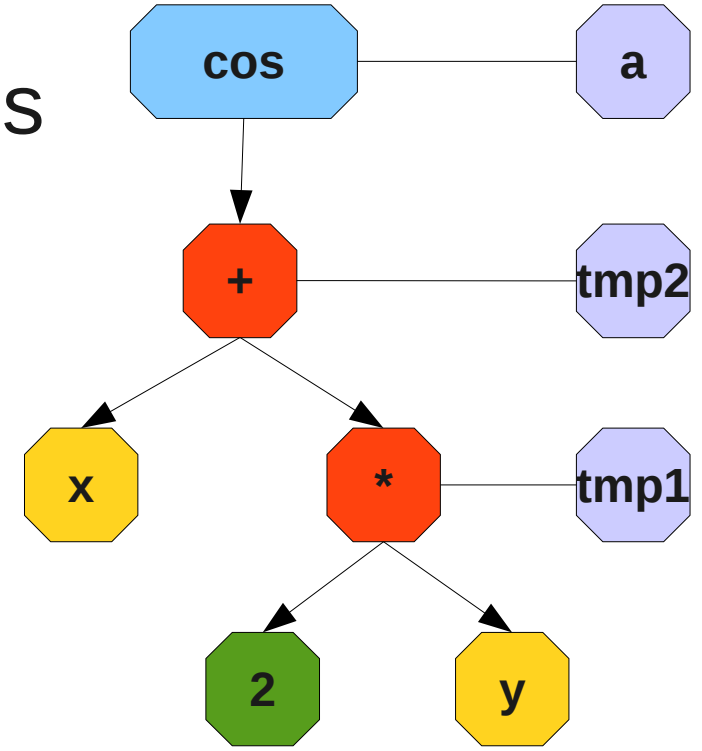

- Il faut une variable temporaire par nœud intermédiaire de l'AST

Code à base d'arbre

- Les résultats intermédiaires sont stockés sur la pile

  a = cos(x+2*y)

  devient

  iload x
  iload y
  iconst_2
  imult
  iadd
  invokestatic Math.cos (I)I

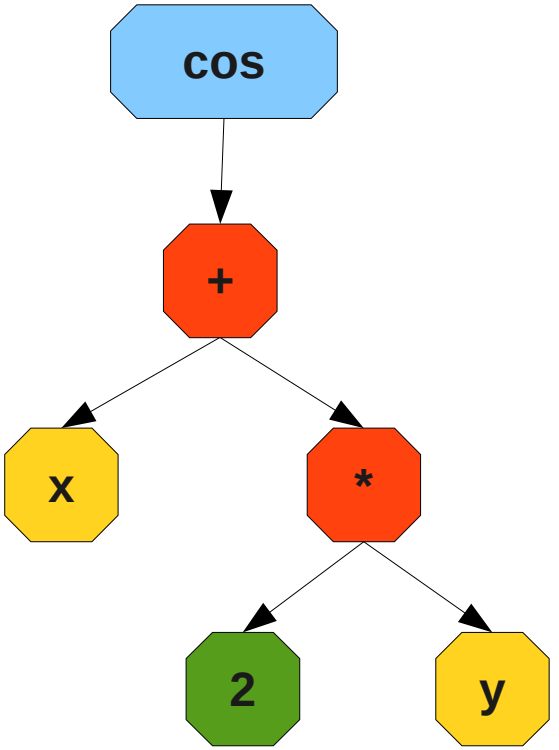

Static Single Assignment

- Permet d'exprimer facilement de nombreuses optimisations

  y = 1
  y = 2
  x = y

  est transformé en

  y1 = 1
  y2 = 2
  x1 = y2

- Si seul x est utilisé, y1 = 1 peut être supprimé

SSA

- Il existe une opération spéciale φ (phi) qui permet d'indiquer une dépendance entre deux variables
- int a;
  if (condition) { a=3; } else { a=4; }
  print a

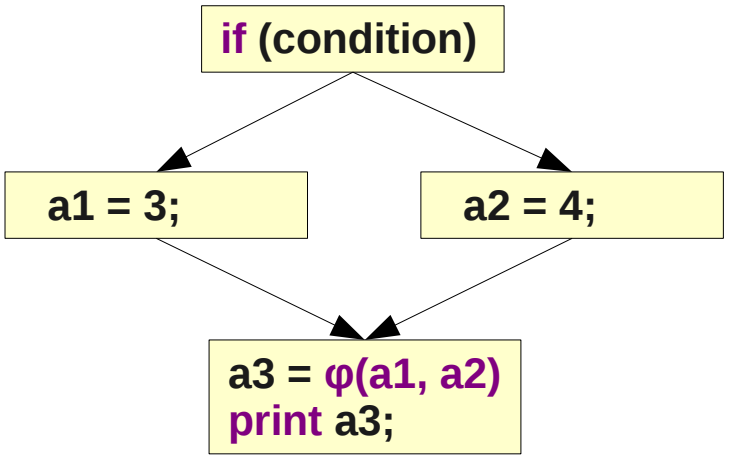

Niveau de langage

- On peut choisir différents niveau de langage intermédiaire
- Exemple :
  - instructions spécifique pour les tableaux
    - On peut tirer partie des procs moderne (MMX, SSE*), ou même générer du bytecode Java
  - Ou transformer en déréférencement de pointeur
    - Le générateur de code est plus simple à écrire car il ne gère qu'une seul abstraction

Exemple

a = array[i]

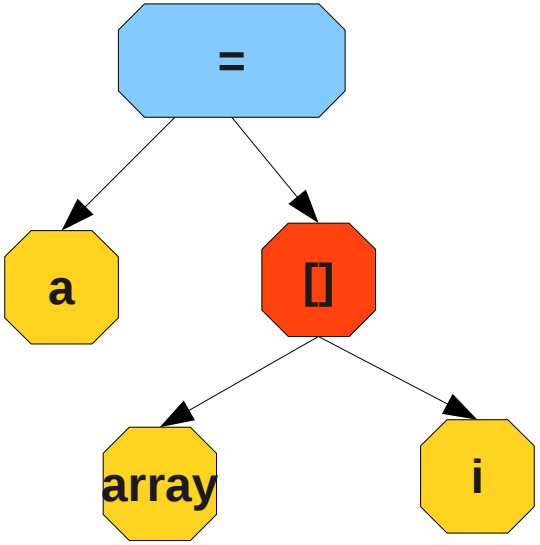

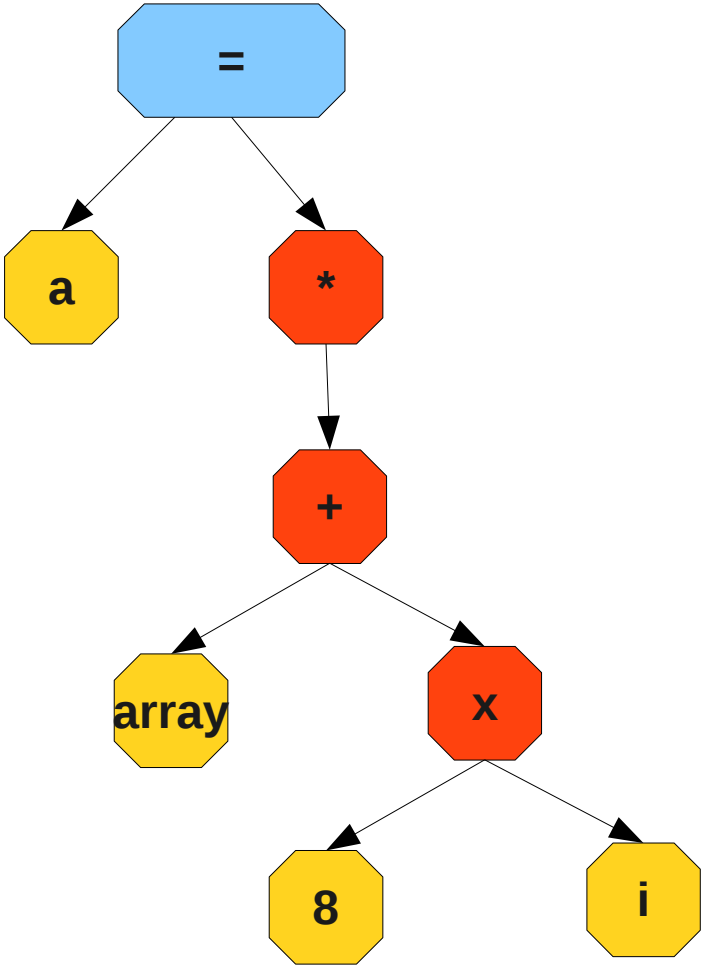

Structure de contrôle

- Les structures de contrôle sont remplacés par du code basé sur des tests et des goto

- Le if

```
int a;
if (test) {
  a = 3;
} else {
  a = 4;
}
print a;
```

```
if (test) goto test

a = 4;
goto end

test:
a = 3;

end:
print a
```

Structure de contrôle

- Boucle for:

```
for (int i = 0;i < 5 ;i = i + 1) {
  print i;
}
print "end";
```

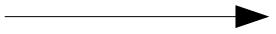

```
i = 0

test:
if (i >= 5) goto end

print i;

continue:
i++;

goto test:

end:
print "end";
```

- Comme ici on sait que i est strictement inférieur à 5 on peut faire une petite optimisation

Structure de contrôle

- Boucle for (optimisé légèrement):

```
for (int i = 0;i < 5 ;i = i + 1) {
  print i;
}
print "end";
```

```
i = 0

test:
print i;

continue:
i++;

if (i < 5) goto test

end:
print "end";
```

```
i = 0

test:
if (i >= 5) goto end

print i;

continue:
i++;

goto test:

end:
print "end";
```

- On peut faire mieux en déroulant la boucle (cf cours optimisations)

Appel de fonction

- A chaque appel de fonction correspond un morceau de pile appelée stack frame
- Lors d'un appel, l'appelant empile les arguments (+ valeur de retour)
- Au retour soit l'appelant soit l'appelée dépile

```
function f(int x):int {
  return if (x == 0) 1 else x * f(x - 1);
}

function main() {
  Int a = 3;
  print f(2);
}
```

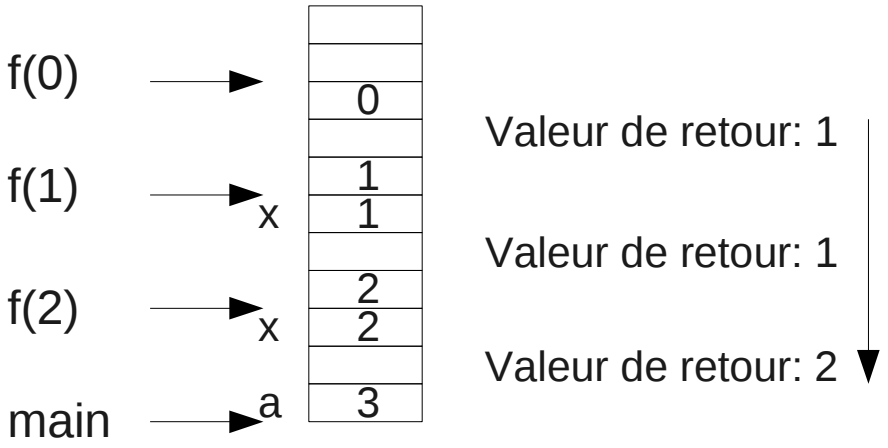

Convention d'appel de fonction

- Il existe plein de conventions d'appel
  - Dépend de l'architecture machine
    x86, x64, SPARC, etc
  - De l'OS (Windows, autre)
  - Si l'appel est un appel système (vers le kernel)

- 2 sortes :
  - Caller clean-up (Pascal, Java)
  - Callee clean-up (C)

Différence entre les conventions

- Nombre de paramètre passé en registre
- Convention d'utilisation de registre
  - exemple:
    - ebp doit pointer sur début stack frame
    - esp sur le haut de la pile

- Un même compilateur peut utiliser plusieurs conventions de compilation
  - si on effectue un appel système
  - si on appel à une librairie externe

Assembleur Java

- Le format binaire de la plateforme Java appelé bytecode est un code intermédiaire utilisant une pile
  - Chaque instruction possède un opcode sur un byte
  - Les opérandes sont:
    - soit des entiers
    - soit des constantes partagé dans un dictionnaire (constant pool)

Anatomie d'un .class

- 2 parties
  - Le constant pool
  - Une description de la classe
    - Modificateurs, nom, héritage etc,
    - Description des champs
    - Description des méthodes
      - Un Attribut nommé "Code" qui contient une tableau d'instruction
- On peut mettre des attributs sur la classe, les champs, les méthodes

Format des descripteurs

- Nom d'une classe
  java/lang/Object
- Descripteur de champs
  B boolean, C char
  D double, F float
  I integer, J long
  S short, Z boolean

  Ljava/lang/Object; classe java.lang.Object
  [int tableau d'int

Format des descripteurs

- Descripteur de method
  (*descs*)*desc_ou_V*
- Exemple:
  ()V renvoie void
  (I)Z prend un int et renvoie un booléen
  (II)V prend deux ints
  (Ljava/lang/Object;I)V prend Object et un int

Exemple de bytecode

- Exemple de HelloWorld avec javap

- public HelloWorld();
  Code:
  0: aload_0
  1: invokespecial #21; //Method **java/lang/Object."<init>":()V**
  4: return

- public static void main(java.lang.String[]);
  Code:
  0: getstatic #14; //Field **java/lang/System.out:Ljava/io/PrintStream;**
  3: ldc #20; //String HelloWorld
  5: invokevirtual #23; //Method **java/io/PrintStream.println:(Ljava/lang/String;)V**
  8: return

Java != bytecode

- En bytecode, le constructeur se nome <init> et <clinit> pour le bloc static
- Les blocks d'initialisations sont recopiés dans les constructeurs
- Les blocs finally sont recopiés dans le cas avec exception et dans le cas sans
- Les appels de méthode indiquent le type de retour
- Il n'y a pas d'exception checked
- Les classes internes n'existe plus. Pour les inners classes un pointeur sur la classe englobante est ajouté et initialisé dans tous les constructeurs (avant l'appel à super ?)
- Les enums sont presque des classes normales
- Il n'y a pas de generics (erasure)

Le constant pool de l'exemple

- Le constant pool est un tableau ou chaque ligne contient un type d'items
  - Class, Fieldref, Methodref, InterfaceMethodref, String, Integer, Float, Long, Double, NameAndType, Utf8
  - Un item peut lui-même référencé d'autres items

```
const #1 = NameAndType      #24:#26;//  out:Ljava/io/PrintStream;
const #2 = Asciz      ([Ljava/lang/String;)V;
const #3 = Asciz      java/lang/Object;
const #4 = Asciz      <init>;
const #5 = class      #3;   //  java/lang/Object
const #6 = NameAndType      #4:#9;//  "<init>":()V
const #7 = class      #18; //  java/io/PrintStream
const #8 = Asciz      Helloworld.j;
const #9 = Asciz      ()V;
...
const #21 = Method#5.#6;      //  java/lang/Object."<init>":()V
...
```

Outils

- Assembleur Java
  - Jasmin
- APIs Java de génération de bytecode
  - ASM, BCEL, SERP
- Afficheur de bytecode Java
  - javap
  - ASM bytecode outline (plugin eclipse)

.class dans eclipse

Eclipse sait afficher les .class

- public class HelloWorld {
- // Method descriptor #11 ()V
  // Stack: 1, Locals: 1
  public HelloWorld();
  0 aload_0 [this]
  1 invokespecial java.lang.Object() [2]
  4 return
- // Method descriptor #2 ([Ljava/lang/String;)V
  // Stack: 2, Locals: 1
  public static void main(java.lang.String[] arg0);
  0 getstatic java.lang.System.out : java.io.PrintStream [14]
  3 ldc <String "HelloWorld"> [20]
  5 invokevirtual java.io.PrintStream.println(java.lang.String) : void [23]
  8 return
- }

Jasmin

```
.class public HelloWorld
.super java/lang/Object
```

- ```
  ; ceci est un commentaire
  .method public <init>()V
     aload_0
     invokespecial java/lang/Object/<init>()V
     return
  .end method
  ```

- ```
  .method public static main([Ljava/lang/String;)V
    getstatic java/lang/System/out Ljava/io/PrintStream;
    ldc "HelloWorld"
    invokevirtual java/io/PrintStream/println(Ljava/lang/String;)V
    return
  .limit stack 2
  .limit locals 1
  .end method
  ```

- Attention au '/' pour accéder au membre ??

Variable locale

- Les paramètres et les variables locales sont stockés au même endroit
  - Les boolean/char/byte/int prenne 1 slot
  - Les doubles et les longs prennent 2 slot
  - Il est possible de réutiliser les slots ?
- Exemple

```
main(String[] args)     slot 0: args
iconst_2
istore 1                slot 1: 2 (int)
iconst_2
i2d
dstore 1                slot 1 et 2: 2.0 (double)
```

Variable locale

- 2 opérations possibles
  - load (iload, lload, fload, dload et aload)
  - store (istore, lstore, fstore, dstore et astore)

- Les opérations sont typés
  - Préfix:

    iload -> int, lload -> long, fload -> float,
    dload -> double et aload -> objet

Opération sur la pile

- Toutes les opérations s'effectue sur la pile
- Chaque case de la pile fait 32 bits
  - Les boolean, byte, short, int, float prennent 1 case
  - les long et double prennent 2 cases

- Exemple:

```
iconst_1      // empile 1
iconst_2      // empile 2
iadd          // dépile 1 et 2 et empile 3
istore 0      // dépile 3 et le stocke
              // dans la varialbe 0
```

Vérificateur

- Pour qu'une classe soit valide pour la machine virtuelle, il faut
  - Que l'on applique les opérations sur les bons types dans la pile et sur les variables locales
  - Que l'on indique le nombre maximal de variables locales, la taille maximal de la pile

- Sinon le vérificateur de bytecode de la machine virtuelle ne permettra pas le chargement de la classe

Max stacks|max locals

- Pour calculer les tailles max, il faut simuler une execution abstraite

- void max(int);
  Code:
  0: iload_1
  1: **ifne 13** // (!=0)
  4: iload_1
  5: i2d
  6: dstore_3
  7: dload_3
  8: d2i
  9: istore_2
  10:**goto15**
  13:iconst_2
  14:istore_2
  15:iload_2
  16:istore_3
  17:**return**

- Résultat: Stack=2, Locals=5

Les constantes

- Il y a plusieurs façon de charger une constante
  - iconst_0, iconst_1 ... iconst_5, iconst_m1
  - bipush [-128, +255]
  - sipush [-37728, +37727]
  - ldc/ldc2, pour toute les constantes pas seulement les integers
- Les booléens sont gérés comme des ints

Manipulation de la pile

- Il existe des instructions pour dupliquer le sommet de pile
- dup
  - duplique 1 valeur
- dup2
  - duplique 2 valeurs ou 1 seul long/double

- Il y a plein d'autres dup_...
- Les dups sont polymorphes

Opérations

- Opération numérique sont typés (préfix i,l,f,d)
  - iadd, isub, imul, idiv, irem
- Opération sur les ints
  - iand (&), ior (|), ixor(^), ineg(~), ishl(<<), ishr(>>), iushr(>>>)
- i++, ou i+=2 existe !
  - iinc 3 2 (ajoute 2 à la variable local 3)

Conversions

- Comme les opérations et les variables sont typés, il faut faire des conversions

- i2b, i2c, i2s, i2d, i2f, i2l,
  l2i, l2f, l2d,
  f2i, f2l, f2d,
  d2i, d2l, d2f

- On ne peut faire les conversions vers byte/char/short qu'à partir d'un int

Branchements

- Inconditionnel
  - goto index d'arrivé
- Conditionnel
  - ifeq, ifne, iflt, ifle, ifgt, ifge (compare à zéro)
  - if_acmp[eq|ne] (comparaison de refs)
  - if_icmp[eq|ne|lt|le|gt|ge] (comparaison d'int)
  - Ifnonnull, ifnull (test à null)
- Sous-routine
  - jsr, ret (plus utilisé depuis là 1.5 en Java)
    - Le vérificateur aime pas !

Test long/float/double

- Le test se fait en deux fois, on test les long/float/double, cela renvoie un int puis on test avec ifeq/ifne...
- Test:
  - lcmp/fcmpg/dcmpg (comparaison, -1, 0, 1)
  - Existe aussi fcmpl/dcmpl (NaN pas traité pareil)
- Exemple:

```
0:   ldc2_w    #16; //double 2.0d
3:   dstore_2
4:   dload_2
5:   ldc2_w    #18; //double 4.0d
8:   dcmpg
9:   ifgt   17
```

Allocation d'un objet

- new Integer(2) est séparé en deux opérations
  - new
  - invokespecial <init> pour appeler les constructeurs
- Si on oublie d'appeler le constructeur le vérificateur plante !
- Exemple:

```
0:  new #16; //class java/lang/Integer
3:  dup
4:  iconst_2
5:  invokespecial  #18; //Method java/lang/Integer."<init>":(I)V
8:  astore_1
```

Checkcast et instanceof

- Checkcast permet de faire un cast
  - Exemple

```
aload_1
checkcast     #16; //class java/lang/Integer
```

- Instanceof fait le test instanceof
  - Exemple

```
aload_1
instanceof    #16; //class java/lang/Integer
```

Création de tableaux

- Tableau de type primitif
  - Newarray

```
iconst_5
newarray int
```

- Tableau d'objet
  - Anewarray

```
iconst_5
anewarray       #21; //class "[I"
```

Rappel les tableaux int[][] sont des tableaux d'objets

Accès aux valeurs des tableaux

- Charge l'élément d'un tableau
  - baload (byte et boolean), caload, iaload, lalod, faload, daload, aaload
  - bastore (byte et boolean), castore, iastore, lastore, fastore, dastore, aastore
- Exemple:

```
iconst_5
newarray int
astore_1
aload_1
iconst_3        // numéro de la case
iconst_5
iastore
aload_1
iconst_2        // numéro de la case
iaload
istore_2
```

Accès aux champs

- getfield/putfield pour les champs d'instance
- getstatic/putstatic pour les champs static

- Exemple:

```
public static void main(java.lang.String[] arg0);
   0  getstatic java.lang.System.out : java.io.PrintStream [14]
   3  ldc <String "HelloWorld"> [20]
   5  invokevirtual java.io.PrintStream.println(java.lang.String) : void [23]
   8  return
```

appels de méthodes

- Il existe 5 appels de méthodes:
  - invokespecial (constructeur et méthode privé de la classe courante)
  - invokesuper (super.)
  - invoke static (appel statique)
  - invokevirtual (appel polymorphe)
  - Invokedynamic (JSR 292)
- On doit avoir dans la pile le receiver (sauf pour invokestatic/invokedynamic) et les arguments

switch

- Il existe deux implantations des switchs
  - Tableswitch (table de branchement)
  - Lookup switch (dichotomie sur les branchements)

- Si les valeurs sont continues

  => tableswitch

lookupswitch

- Avec Jasmin:

```
lookupswitch
    3 : label1
    7 : label2
    default : defLabel

label1:
    ; case 3
    goto break

label2:
    ; case 7
    goto break;

defLabel:
    ; default

break:
```

tableswitch

- Avec Jasmin:

```
tableswitch 0
    label1
    label2
    default : defLabel

label1:
    ; case 0
    goto break

label2:
    ; case 1
    goto break;

defLabel:
    ; default

break:
```

Exceptions

- Les exceptions sont gérer dans une table stockée à la suite du bytecode
- On indique pour un type d'exception levée entre deux offsets d'instructions là où il faut sauter
- Le sommet de la pile du handler d'exception contient l'exception levée
- Avec Jasmin:
  .catch <classname> from <label1> to <label2> using <label3>

Exceptions

- public static void main(java.lang.String[]);
  Code:
  ```
     0: aload_0
     1: iconst_0
     2: aaload
     3: invokestatic  #16   // Method java/lang/Integer.parseInt:(Ljava/lang/String;)I
     6: pop
     7: goto 18
    10: astore_1
    11: getstatic     #22     // Field java/lang/System.out:Ljava/io/PrintStream;
    14: aload_1
    15: invokevirtual #28   // Method java/io/PrintStream.println:(Ljava/lang/Object;)V
    18: return
  ```
- Exception table:
  ```
     from    to  target type
         0     7    10      Class java/lang/NumberFormatException
  ```

Finally

- public static void main(java.lang.String[]);
  Code:
  ```
     0: aload_0
     1: iconst_0
     2: aaload
     3: invokestatic  #16 // Method java/lang/Integer.parseInt:(Ljava/lang/String;)I
     6: pop
     7: goto 21
    10: astore_1
    11: getstatic     #22     // Field java/lang/System.out:Ljava/io/PrintStream;
    14: ldc           #28     // String finally
    16: invokevirtual #30 // Method java/io/PrintStream.println:(Ljava/lang/String;)V
    19: aload_1
    20: athrow
    21: getstatic     #22     // Field java/lang/System.out:Ljava/io/PrintStream;
    24: ldc           #28     // String finally
    26: invokevirtual #30  // Method java/io/PrintStream.println:(Ljava/lang/String;)V
    29: return
  ```

- Exception table:
  ```
     from    to  target type
         0    10    10   any
  ```