# Génération de code trois adresses

Alexis Nasr
Carlos Ramisch
Manon Scholivet
Franck Dary

Compilation – L3 Informatique
Département Informatique et Interactions
Aix Marseille Université

# Représentations intermédiaires

- Arbre abstrait → représentation intermédiaire “haut niveau”
  Assez structurée, proche du langage source
- Code trois adresses → représentation intermédiaire “bas niveau”
  Linéaire, peu structurée, proche du langage machine
- La génération de code trois adresses s’effectue pendant le parcours de l’arbre abstrait

# Exemple : code trois adresses

Arbre abstrait :

Code-source en L :

```
entier a;
main(){
  a = lire();
  si a alors {
    ecrire(3+a+1);
  }
}
```

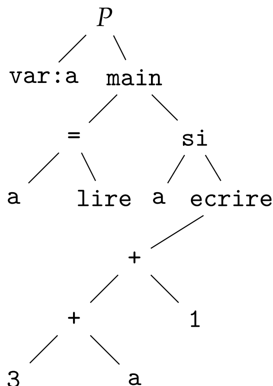


Code 3 adresses :

```
01 : fbegin
02 : t0 = read
03 : a = t0
04 : if a == 0 goto 8
05 : t1 = 3 + a
06 : t2 = t1 + 1
07 : write t2
08 : fend
```

# Intérêt du code trois adresses

- Se concentrer sur la linéarisation du programme :
  - dérouler les boucles
  - désimbriquer les blocs de code
  - décomposer les expressions complexes en une séquence d'opérations
- Faire abstraction des détails propres à chaque architecture :
  - Organisation de la mémoire (segments mémoire de pile, tas, ...)
  - Taille (nombre d'octets) et emplacement des variables
  - Nombre de registres disponibles
  - Transferts registres $\leftrightarrow$ mémoire
  - Particularités des instructions (p.ex. `idiv` opère sur le registre `eax`)
- **Compromis** : facile à convertir en code machine mais suffisamment générique pour s'adapter aux différentes architectures

# Représentation en mémoire du code trois adresses

- Le code trois adresses est une séquence d'instructions
- Toute instruction correspond à un indice dans la séquence, son adresse
- Chaque instruction prend la forme :

```
opcode a1 a2 r
```

- Le code de l'opération `opcode` est obligatoire
- Chaque instruction a au plus trois opérandes
  - `a1` et `a2` sont généralement les opérandes d'une opération
  - `r` est généralement le résultat d'une opération
- Les opérations sont simples : arithmétiques, logiques, sauts, etc.

# Les Opérandes

- Les opérandes des instructions peuvent être :
  1. Des constantes : *1, -5, 3455*
  2. Des variables du programme source : `max, a`
  3. Des étiquettes du code trois adresses : `fin, e1`
  4. Des variables temporaires générées lors de la traduction : `t0, t1`
- Les constantes et les variables existent déjà dans le programme source (donc dans l'arbre abstrait)
- Les étiquettes et les variables temporaires sont créées lors du processus de génération

# Les variables temporaires

- Dans le langage source, les expressions peuvent être complexes :
  `delta = b * b - 4 * a * c`
- Dans le code trois adresses, ces expressions complexes ne sont pas autorisées (plus de trois opérandes)
- Il faut les décomposer et stocker des valeurs intermédiaires dans des variables temporaires :

```
01 : t0 = b × b
02 : t1 = 4 × a
03 : t2 = t1 × c
04 : delta = t0 - t2
```

- Les variables temporaires (ou simplement temporaires) sont générées à la demande pendant la traduction
- Nous les noterons `t0, t1, t2 ...` par convention

# Etiquettes

- Une étiquette est un nom symbolique unique donné à une adresse
- Cela permet de rendre le code plus lisible
- Les étiquettes sont généralement représentées par un identifiant qui précède l'instruction

Au lieu d'écrire :

```
04 : if a == 0 goto 8
05 : t1 = 3 + a
06 : t2 = t1 + 1
07 : write t2
08 : fend
```

nous écrirons :

```
04     : if a == 0 goto fin
05     : t1 = 3 + a
06     : t2 = t1 + 1
07     : write t2
08 fin : fend
```

# Les variables I

- Les variables sont des noms appartenant au langage source
- Dans le code trois adresses, nous avons besoin d'informations sur ces variables contenues dans la table des symboles
- Le variables sont représentées par des pointeurs vers la table des symboles

# Les variables II

## Collisions de nom

- Il faut éviter les collisions de nom avec les étiquettes et les temporaires générées lors de la traduction
- Exemple : le programme source déclare une variable `t0` et la génération de code génère une nouvelle variable temporaire `t0`
- Solution :
  - Les noms de variables du code source seront systématiquement préfixés d'un `v` dans le code trois adresses
    `max` → `vmax`
  - Les noms de fonctions du code source seront systématiquement préfixés d'un `f` dans le code trois adresses :
    `main` → `fmain`
  - La génération du code trois adresses ne génèrera aucune étiquette ou temporaire dont le nom commence par `v` ou `f`

# Les variables III

## Le cas des tableaux

- Les variables de type tableau sont toujours indicées
- En L ces indices peuvent être des expressions quelconques
- En code 3 adresses, ces indices sont uniquement des temporaires ou des constantes
- Par exemple, `tab[t2]` et `tab[5]`, mais pas `tab[i]` ou `tab[t0+1]`

# Les instructions

| Type | Opérations | `a1` | `a2` | `r` | Syntaxe |
|---|---|---|---|---|---|
| arithmétique | `+ - * /` | `ctv` | `ctv` | `tv` | `r = a1 op a2` |
| affectation | `=` | `ctv` | | `tv` | `r = a1` |
| saut test | `== < <= > >=` | `ctv` | `ctv` | `e` | `if a1 op a2 goto r` |
| saut direct | `goto` | `e` | | | `goto a1` |
| appel fonction | `call` | `e` | | `tv` | `r = call a1` ou `call a1` [1] |
| lecture | `read` | | | `tv` | `r = read` |
| écriture | `write` | `ctv` | | | `write a1` |
| e/s fonction | `param ret` | `ctv` | | | `op a1` |
| début/fin fonc. | `fbegin fend` | | | | `fbegin`, `fend` |

- Chaque instruction accepte certains types d'opérandes `a1`, `a2` et `r` :

  constantes (`c`), temporaires (`t`), variables (`v`) ou étiquettes (`e`)
- Exemples :
  - l'opérande `a1` d'un saut direct est une étiquette `e`
  - l'opérande `r` d'une op. arith. est un temporaire ou variable (`tv`).
- Pas d'opérateurs de comparaison, pas d'opérateurs logiques

1. `r` est optionnel, selon que l'appel est une expression ou instruction.

# Les instructions arithmétiques et d’affectation

- Format :
  - `r = a1 op a2`
  - `r = a1`
- Le résultat `r` ne peut pas être une constante
- Sémantique identique aux opérations arithmétiques classiques
- Limitation aux expressions simples, pas plus de trois adresses
- Le parcours de l’arbre abstrait génère des temporaires pour stocker les variables intermédiaires des expressions
- Les expressions complexes sont transformées en instructions arithmétiques simples dans le code trois adresses
- Cela s’applique aussi aux cases de tableaux :
  `a = tab[ i ]` → `t0 = vi; va = tab[t0]`

# Les sauts

- Formats :
  - `if a1 op a2 goto r`
  - `goto r`
  - `call r`
- Les sauts changent le cours de l'exécution du programme
- Sauts conditionnels : vont à la ligne cible `r` si une condition portant sur les adresses `a1` et `a2` est vraie :

```
if t4 < 10 goto e12
```

- Sauts inconditionnels : la prochaine instruction est la cible `r`
  - `goto r` : pas de mémorisation de la ligne courante
- La traduction en code trois adresses crée des nouvelles étiquettes `e0, e1, e2...` qui seront la cibles des sauts

# Déclarations et appels de fonctions

- Instructions gardant la trace des fonctions du langage source :
  - `fbegin` marque le début d'une déclaration de fonction. Cette instruction n'a aucun effet sur l'état du programme. Sa ligne est toujours étiquetée, p.ex. `fmain: fbegin`.
  - `ret` et `param` prennent une adresse (`ctv`). Elles communiquent un paramètre ou une valeur de retour entre la fonction appelante et la fonction applée, p.ex. `ret t5`.
  - `call r` mémorise la prochaine ligne à exécuter et change le cours de l'exécution vers la cible `r`.
  - `fend` marque la fin d'une déclaration de fonction, changeant le cours de l'exécution vers la dernière adresse sauvegardée par `call`.
- La cible `r` d'un `call r` est toujours une instruction `fbegin` (début de fonction) étiquetée `r`

# Instructions spéciales

- `r = read` lit un entier depuis le clavier et le stocke dans `r` (temporaire ou variable)
- `write a1` écrit un entier `a1` (temporaire, constante ou variable) sur le terminal

# Traduction

- La traduction arbre abstrait $\rightarrow$ code trois adresses se fait lors d'un parcours en profondeur de l'arbre
- Nous utiliserons des grammaires attribuées fondées sur :
  - Une grammaire (ambiguë) correspondant à l'arbre abstrait [2]
  - Des attributs synthétisés pour les variables intermédiaires
  - Une fonction *gen(·)* qui génère une ligne de code trois adresses
  - Des fonctions *newtemp()* et *newetiq()* qui génèrent un nouveau temporaire/étiquette uniques

2. Un arbre de dérivation de cette grammaire est un arbre abstrait

# Grammaire

1. $P \rightarrow LD\ LD$

2. $LD \rightarrow D\ LD$
3. $LD \rightarrow$ `null`

4. $D \rightarrow$ `fct id` $LD\ LD\ LI$
5. $D \rightarrow$ `var id`
6. $D \rightarrow$ `var id taille`

7. $V \rightarrow$ `id`
8. $V \rightarrow$ `id[` $E$ `]`
9. $LI \rightarrow I\ LI$
10. $LI \rightarrow$ `null`

11. $I \rightarrow$ `aff` $V\ E$
12. $I \rightarrow$ `si` $E\ LI\ LI$
13. $I \rightarrow$ `tq` $E\ LI$
14. $I \rightarrow$ `app` $APP$
15. $I \rightarrow$ `ret` $E$
16. $I \rightarrow$ `ecr` $E$
17. $APP \rightarrow$ `id` $LE$
18. $LE \rightarrow E\ LE$
19. $LE \rightarrow$ `null`

20. $E \rightarrow E$ `op2` $E$
21. $E \rightarrow$ `op1` $E$
22. $E \rightarrow V$
23. $E \rightarrow$ `entier`
24. $E \rightarrow APP$
25. $E \rightarrow$ `lire`

# Traduction des expressions I

- Principe général : à l'issue de l'exécution du code correspondant à une expression, le résultat de cette dernière doit se trouver dans une variable ou un temporaire
- Quatre cas :
  - *Constante* : la constante est renvoyé telle quelle
  - *Variable* : le pointeur de la variable dans la table des symboles est renvoyé
  - *Appel de fonction* : les paramètres de la fonction sont évalués, la fonction est appelée, et la valeur de retour de la fonction est mise dans un nouveau temporaire, qui est renvoyé
  - *Opération* : l'expression est décomposée et le résultat final est mis dans un temporaire, qui est renvoyé

# Opérations arithmétiques, constantes et variables

| Production | | | Action sémantique |
|---|---|---|---|
| $E$ | $\rightarrow$ | $E_1 + E_2$ | $E.t = newtemp()$ |
| | | | $gen(E.t = E_1.t + E_2.t)$ |
| $E$ | $\rightarrow$ | $E_1 - E_2$ | $E.t = newtemp()$ |
| | | | $gen(E.t = E_1.t - E_2.t)$ |
| $E$ | $\rightarrow$ | $E_1 * E_2$ | $E.t = newtemp()$ |
| | | | $gen(E.t = E_1.t \times E_2.t)$ |
| $E$ | $\rightarrow$ | $E_1 / E_2$ | $E.t = newtemp()$ |
| | | | $gen(E.t = E_1.t \div E_2.t)$ |
| $E$ | $\rightarrow$ | `nb` | $E.t = \texttt{nb}.val$ |
| $E$ | $\rightarrow$ | `var` | $E.t = \texttt{var}.val$ |

Attribut synthétisé $t$ : résultat intermédiaire

# Cases des tableaux

Si l'indice est entier ou temporaire, pas de temporaire supplémentaire
Si l'indice est une variable, nouveau temporaire nécessaire

| Production | Action sémantique |
|---|---|
| $E \rightarrow$ `var` [ $E_1$ ] | $\begin{cases} i = E_1.t & \text{si } type(E_1.t) = \text{temp ou const} \\ i = newtemp() & \\ gen(i = E_1.t) & \text{sinon} \end{cases}$ <br> $E.t = \texttt{var}[i]$ |

# Affectations

| Production | Action sémantique |
|---|---|
| $I \rightarrow$ `var` = $E$ ; | $gen(\texttt{var} = E.t)$ |
| $I \rightarrow$ `var` [ $E$ ] = $E_1$ | $\begin{cases} i = E.t & \text{si } type(E.t) = \text{temp ou con} \\ i = newtemp() & \\ gen(i = E.t) & \text{sinon} \end{cases}$<br>$gen(\texttt{var}[i] = E_1.t)$ |

# Comparaisons et opérateurs logiques

- Pas d'opérateurs de comparaison ni logiques
- Opérations bit-à-bit versus logiques
- Valeurs booléennes représentées par des entiers
- $0 \rightarrow$ FAUX, $\neq 0 \rightarrow$ VRAI
- Convention : VRAI représentée par 1
- Évaluation court-circuit (optimisée)
  - FAUX & $x$ = FAUX $\forall x$
  - VRAI | $x$ = VRAI $\forall x$

# Comparaisons

| Production | Action sémantique |
|---|---|
| $E \rightarrow E_1 < E_2$ | $\texttt{e1} = newetiq()$ |
| | $\texttt{e2} = newetiq()$ |
| | $E.t = newtemp()$ |
| | $gen(\texttt{if } E_1.t < E_2.t \texttt{ goto e1})$ |
| | $gen(E.t = 0)$ |
| | $gen(\texttt{jump e2})$ |
| | $gen(\texttt{e1} : E.t = 1)$ |
| | $gen(\texttt{e2} :)$ |

# Opérations logiques

| Production | Action sémantique |
|---|---|
| $E \rightarrow E_1$ & $E_2$ | e1 $= newetiq()$ |
| | e2 $= newetiq()$ |
| | $E.t = newtemp()$ |
| | $gen($if $E_1.t = 0$ goto e1$)$ |
| | $gen($if $E_2.t = 0$ goto e1$)$ |
| | $gen(E.t = 1)$ |
| | $gen($jump e2$)$ |
| | $gen($e1 : $E.t = 0)$ |
| | $gen($e2 :$)$ |

- Évaluation avec court-circuit :
  $\rightarrow$ $E_2$ n'est pas évaluée si $E_1$ FAUX

# Instructions de contrôle

| Production | Action sémantique |
|---|---|
| $I \rightarrow$ `tq` $E\ LI$ | $gen($`test :`$)$ |
| | $E.code$ |
| | $gen($`if` $E.t = 0$ `goto suite`$)$ |
| | $LI.code$ |
| | $gen($`goto test`$)$ |
| | $gen($`suite :`$)$ |

# Instructions de contrôle

| Production | | | Action sémantique |
|---|---|---|---|
| $I$ | $\rightarrow$ | $\texttt{si}\ E\ LI_1\ LI_2$ | $E.code$ |
| | | | $gen(\texttt{if}\ E.t = 0\ \texttt{goto}\ \texttt{faux})$ |
| | | | $LI_1.code$ |
| | | | $gen(\texttt{goto}\ \texttt{suite})$ |
| | | | $gen(\texttt{faux}\ :)$ |
| | | | $LI_2.code$ |
| | | | $gen(\texttt{suite}\ :)$ |

# Entrées et sorties

| Production | | | Action sémantique |
|---|---|---|---|
| $E$ | $\rightarrow$ | `lire` | $E.t = newtemp()$<br>$gen(E.t = \texttt{read})$ |
| $I$ | $\rightarrow$ | `ecrire` | $gen(\texttt{write}\ E.t)$ |