中国科学技术大学
University of Science and Technology of China

USTC, CHINA
ADSLAB
先进数据系统实验室

《编译原理与技术》
代码生成

计算机科学与技术学院
李 诚
13/12/2018

本章内容

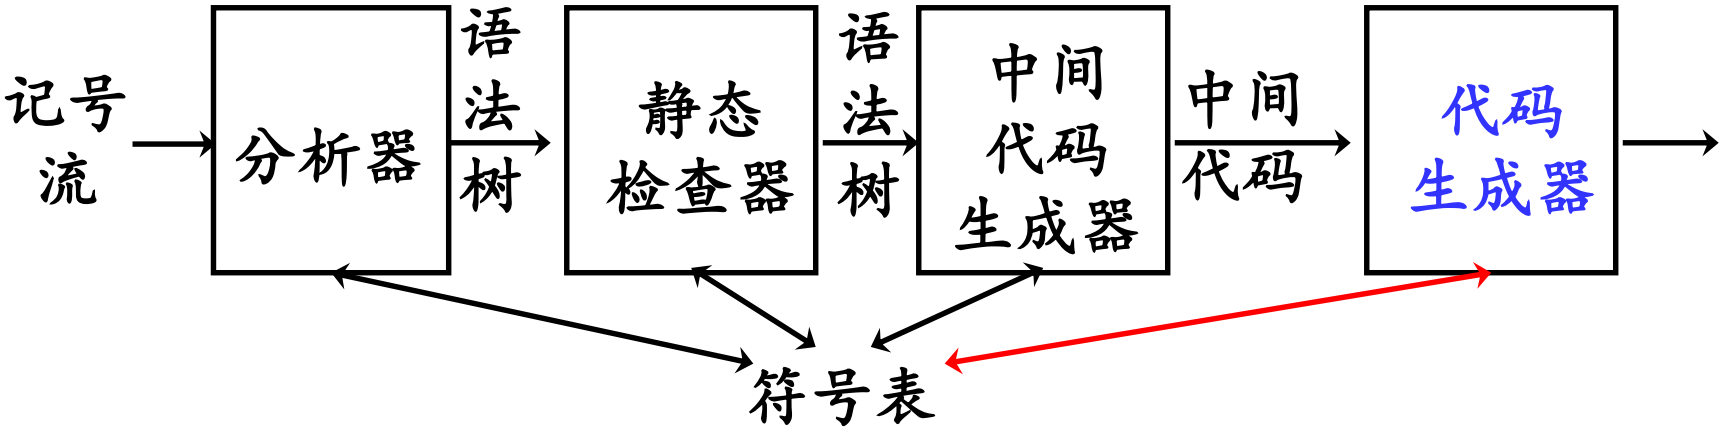

要点讲解：

- 一个简单的代码生成算法，将中间代码IR映射成为可以在目标机器上运行的指令序列
- 涉及目标机器指令选择，寄存器分配和计算次序选择等基本问题

代码生成器设计中的问题

- 目标程序
- 指令选择
- 寄存器的分配和指派
- 计算次序

目标：语义正确+资源有效利用

代码生成器设计中的问题

- 目标程序(target program)
  - 绝对机器语言程序(absolute machine-language …)
    - 目标程序将装入到内存的固定地方
    - 粗略地说，相当于现在的可执行目标模块（第11章介绍）
  - 可重定位目标模块(relocatable object module)
    - 代码中含重定位信息，以适应重定位要求
      - linker/loader

代码生成器设计中的问题

❑目标程序

❖可重定位目标模块

```
.L7:
        testl %eax,%eax
        je .L3
        testl %edx,%edx
        je .L7
        movl %edx,%eax
        jmp .L7
.L3:
        leave
        ret
```

可重定位目标模块中，需要有蓝色部分的重定位信息

❑目标程序

- ❖绝对机器语言程序
  - ➢目标程序将装入到内存的固定地方
  - ➢粗略地说，相当于现在的可执行目标模块（第11章介绍）
- ❖可重定位目标模块
  - ➢代码中含重定位信息，以适应重定位要求
  - ➢允许程序模块分别编译
  - ➢调用其它先前编译好的程序模块

代码生成器设计中的问题

❑目标程序

- ❖绝对机器语言程序
- ❖可重定位目标模块
  - ➢代码中含重定位信息，以适应重定位要求
  - ➢允许程序模块分别编译
  - ➢调用其它先前编译好的程序模块
- ❖汇编语言程序(assembly-language program)
  - ➢免去编译器重复汇编器的工作
  - ➢从教学角度，增加可读性

Risc vs. Cisc reference
https://cs.stanford.edu/people/eroberts/courses/soco/projects/risc/risccisc/

代码生成器设计中的问题

❑指令的选择(instruction selection)

- ❖目标机器指令系统的性质决定了指令选择的难易程度，指令系统的统一性和完备性是重要的因素
- ❖指令的速度和机器特点是另一些重要的因素

代码生成器设计中的问题

- 不考虑目标程序的效率和指令的代价，逐条语句地产生代码，常常得到低质量的代码

例：三地址语句x = y + z (x，y和z都静态分配)

```
MOV     y,    R0    /* 把y装入寄存器R0 */
ADD     z,    R0    /* 把z加到R0上 */
MOV     R0,   x     /* 把R0存入x中 */
```

代码生成器设计中的问题

语句序列 a = b + c

d = a + e

的一种目标代码如下：

```
MOV     b,    R0
ADD     c,    R0
MOV     R0,   a
MOV     a,    R0
ADD     e,    R0
MOV     R0,   d
```

代码生成器设计中的问题

语句序列 a = b + c

d = a + e

的一种目标代码如下：

```
MOV     b,    R0
ADD     c,    R0
MOV     R0,   a
MOV     a,    R0
ADD     e,    R0
MOV     R0,   d
```

由于a的值仍然存于寄存器R0中，因此该指令是冗余的。

代码生成器设计中的问题

语句序列 a = b + c

d = a + e

的一种目标代码如下：

```
MOV     b,    R0
ADD     c,    R0
MOV     R0,   a
MOV     a,    R0
ADD     e,    R0
MOV     R0,   d
```

如果a不再被使用，该指令也可以删除。

代码生成器设计中的问题

- 同一中间表示代码可以由多组指令序列来实现，但不同实现之间的效率差别是很大的。

例：语句a = a + 1可以有两种实现方式

```
MOV     a,      R0
ADD    #1,      R0
MOV     R0,     a
```

```
INC a
```

- 因此，生成高质量代码需要知道指令代价。

代码生成器设计中的问题

- 除了考虑指令的代价和序列长度外，我们还需要考虑运算对象和结果如何存储的问题。

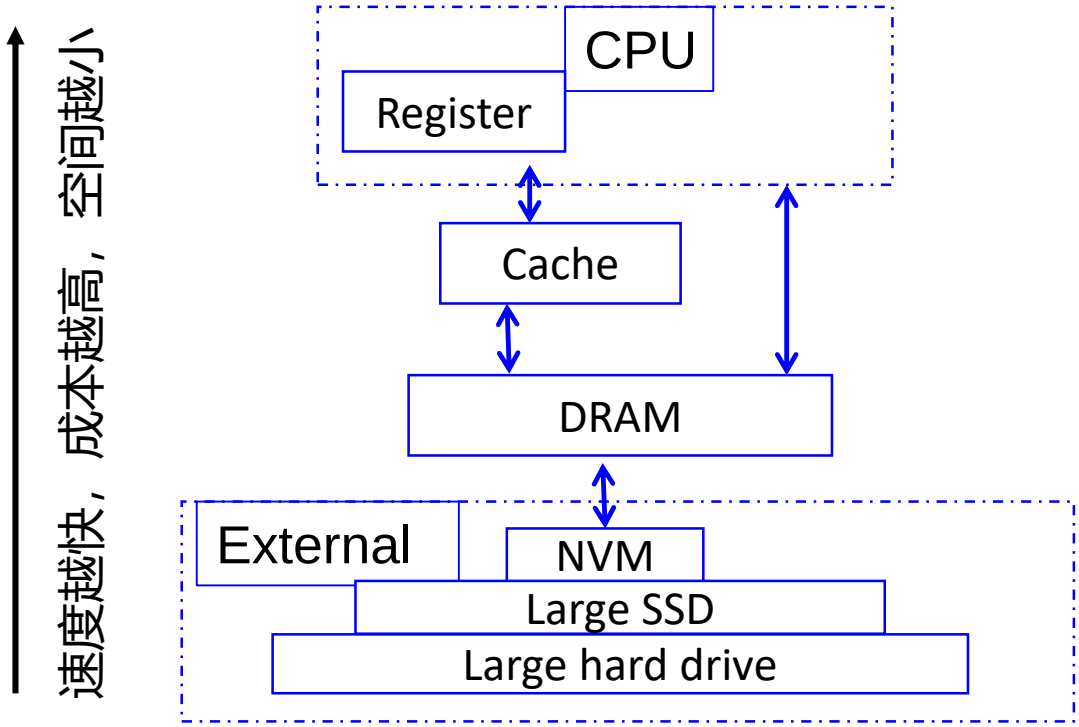

代码生成器设计中的问题

- 除了考虑指令的代价和序列长度外，我们还需要考虑运算对象和结果如何存储的问题。

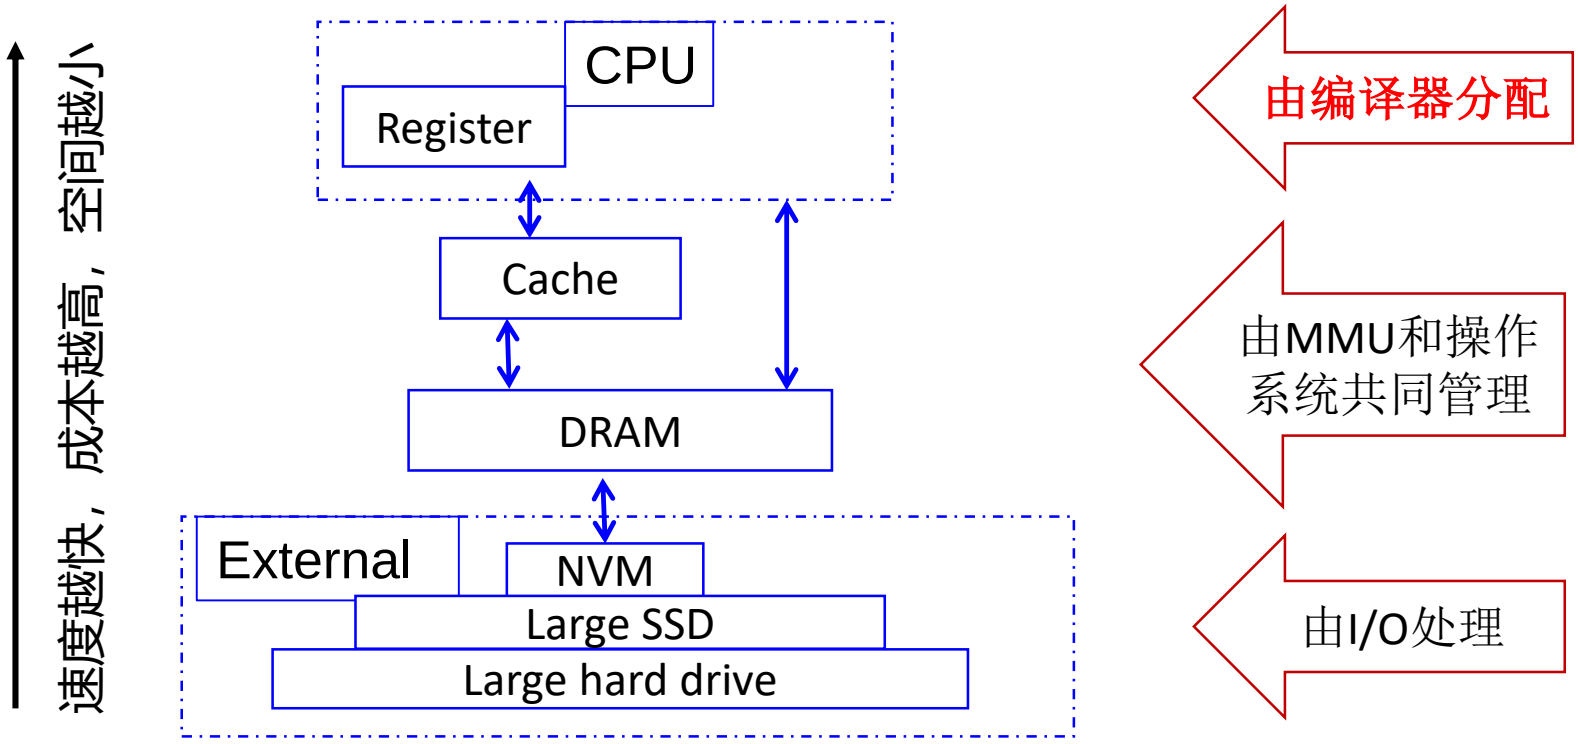

代码生成器设计中的问题

- 寄存器的合理使用：运算对象处于寄存器和处于内存相比，指令要短一些，执行也快一些
  - 寄存器分配(register allocation)
    - 选择驻留在寄存器中的一组变量
  - 寄存器指派(register assignment)
    - 挑选变量要驻留的具体寄存器

代码生成器设计中的问题

- 计算次序的选择(evaluation order)

  程序中计算的执行次序会影响目标代码的执行效率

- 如，对表达式的计算而言，一种计算次序可能会比其它次序需要较少的寄存器来保存中间结果

- 选择最佳计算次序是一个NP完全问题

目标语言

- 目标机器指令集
- 指令代价

❑一个简单目标机器的指令系统

- ❖字节寻址，四个字节组成一个字
- ❖有*n*个通用寄存器R0, R1, …, Rn-1
- ❖二地址指令： op 源，目的

MOV {源传到目的}

ADD {源加到目的}

SUB {目的减去源}

目标语言

❑寻址模式和它们的汇编语言形式及附加代价

模式	形式	地址	附加代价
绝对地址	M	M	1
寄存器	R	R	0
变址	*c*(R)	*c* + *contents*(R)	1
间接寄存器	*R	*contents*(R)	0
间接变址	**c*(R)	*contents*(*c* + *contents*(*R*))	1
直接量	#*c*	*c*	1

❑例 指令实例

MOV R0, M

MOV 4(R0), M

4(R0)的值：*contents*(4 + *contents*(R0))

MOV *4(R0), M

***4(R0)的值：*contents*(*contents*(4 + *contents*(R0)))**

MOV #1, R0

❑指令的代价(instruction costs)

- ❖在上述简单的目标机器上，指令代价简化为

1 + 指令的源和目的寻址模式(addressing mode)的附加代价

❑寻址模式和它们的汇编语言形式及附加代价

模式	形式	地址	附加代价
绝对地址	M	M	1
寄存器	R	R	0
变址	*c*(R)	*c* + *contents*(R)	1
间接寄存器	*R	*contents*(R)	0
间接变址	**c*(R)	*contents*(*c* + *contents*(*R*))	1
直接量	#*c*	*c*	1

- 指令代价简化为

  1 + 指令的源和目的地址模式的附加代价

指令	代价
MOV R0，R1	
MOV R5，M	
ADD #1，　R3	
SUB 4(R0), *12(R1)	

- 指令代价简化为

  1 + 指令的源和目的地址模式的附加代价

指令	代价	
MOV R0，R1	1	寄存器
MOV R5，M	2	寄存器+内存
ADD #1，R3	2	常量+寄存器
SUB 4(R0), *12(R1)	3	变址+间接变址

目标语言

- 例 a = b + c， a、b和c都静态分配内存单元
  - 可生成

```
MOV b, R0
ADD c, R0
MOV R0, a
```

  - 也可生成

```
MOV b, a
ADD c, a
```

目标语言

- 例 a = b + c， a、b和c都静态分配内存单元
  - 可生成

```
MOV b, R0
ADD c, R0          代价= 6
MOV R0, a
```

  - 也可生成

```
MOV b, a
ADD c, a           代价= 6
```

- 例 a = b + c， a、b和c都静态分配内存单元
  - 若R0，R1和R2分别含a，b和c的地址，则可生成

    MOV *R1, *R0

    ADD *R2, *R0　　代价= 2
  - 若R1和R2分别含b和c的值，并且b的值在这个赋值后不再需要，则可生成

    ADD R2, R1

    MOV R1, a　　代价= 3

代码生成器的输入

- 中间代码IR的表示
- 基本块
- 流图
- 循环

❑三地址代码(three-address code)

一般形式：$x = y\ op\ z$

例 表达式 $x + y * z$ 翻译成的三地址语句序列是

$t_1 = y * z$

$t_2 = x + t_1$

❑怎样为三地址语句序列生成目标代码?

先给出本节用例

```
prod = 0;
i = 1;
do {
    prod = prod + a[i] * b[i];
    i = i +1;
} while (i <= 20);
```

其三地址代码见右边

(1) prod = 0
(2) i = 1
(3) $t_1 = 4 * i$
(4) $t_2 = a[t_1]$
(5) $t_3 = 4 * i$
(6) $t_4 = b[t_3]$
(7) $t_5 = t_2 * t_4$
(8) $t_6 = prod + t_5$
(9) $prod = t_6$
(10) $t_7 = i + 1$
(11) $i = t_7$
(12) if i <= 20 goto (3)

基本块和流图

❑基本块

连续的语句序列，控制流从它的开始进入，并从它的末尾离开，没有停止或分支的可能性（末尾除外）

❑流图(flow graph)

用有向边表示基本块之间的控制流信息，基本块作为结点

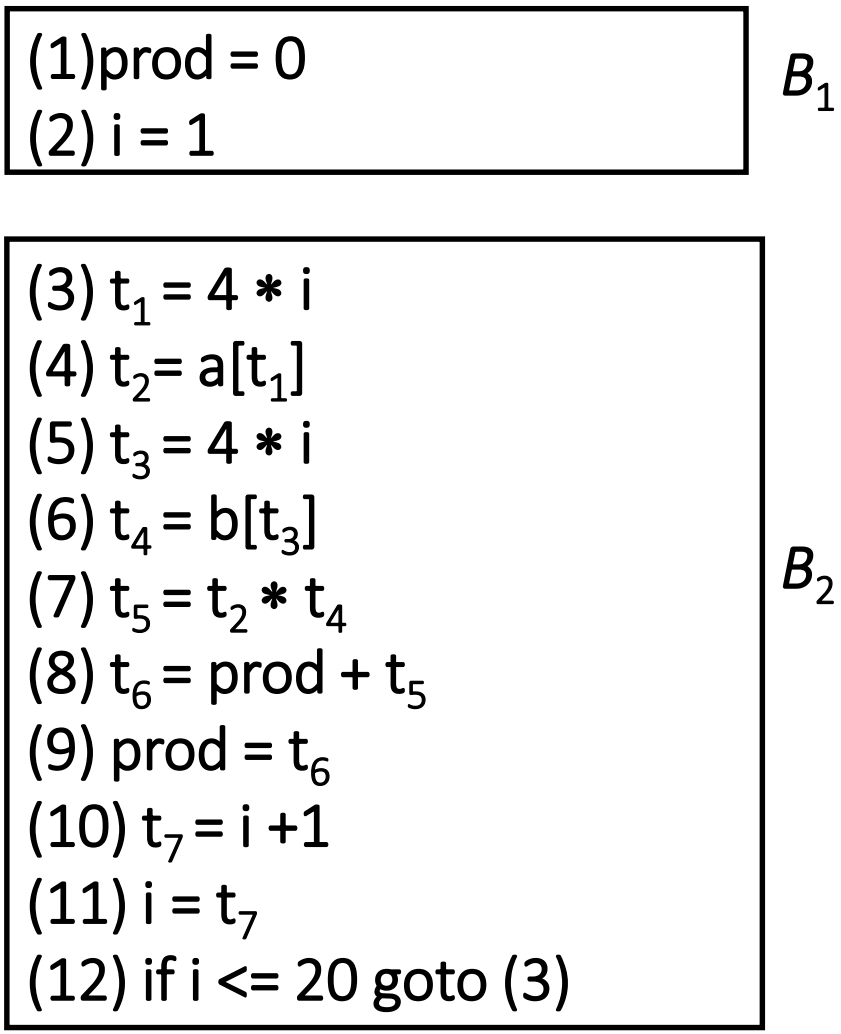

- 如果下列条件成立，我们就说流图中的一个结点集合L是一个循环：
  - 该集合中所有结点是强连通的。
  - 该集合有唯一的入口结点。
- 不包含其他循环的循环叫做内循环

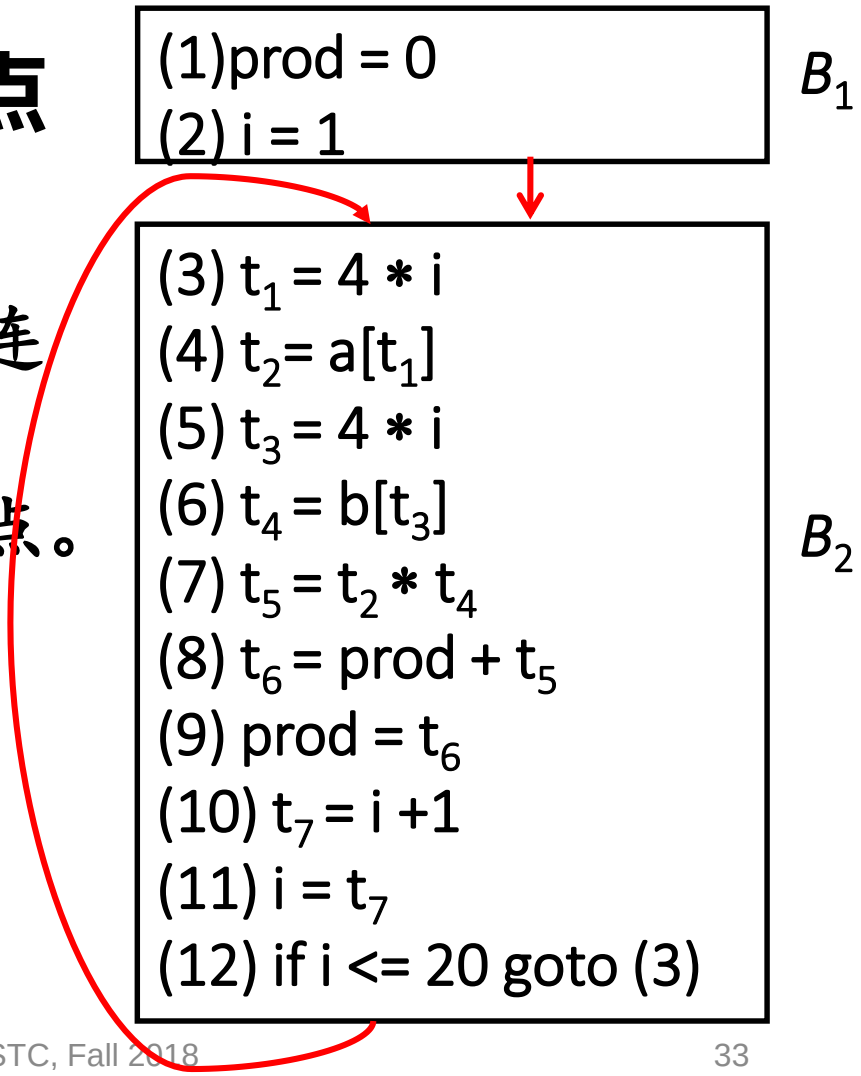

下次引用信息

- 中间代码分析可以记录变量在整个计算过程中被使用的情况，以帮助寄存器的分配和释放
- 名字的引用(use)
  - 三地址码语句i为x赋值
  - 语句j将x作为运算对象，且i到j的控制流路径中无其他对x的赋值语句
  - 语句j引用了语句i计算的x值
- 对每一个基本块，反向扫描，对语句x = y op z，在符号表中记录x，y，z是否活跃或会被下次引用

一个简单的代码生成器

中国科学技术大学
University of Science and Technology of China

- 寄存器和地址的描述
- 代码生成算法
- 寄存器选择函数
- 为特殊语句产生代码

一个简单的代码生成器

❑基本考虑：

- ❖依次考虑基本块的每个语句，为其产生代码
- ❖假定三地址语句的每种算符都有对应的目标机器算符
- ❖假定计算结果留在寄存器中尽可能长的时间，除非(因为本算法的分配方式以基本块为主)：
  - ➢该寄存器要用于其它计算，或者
  - ➢到基本块结束

为此，在生成代码过程中需要记录一些信息

一个简单的代码生成器

❑寄存器描述和地址描述

例:对a = b + c

❖如果寄存器Ri含b，Rj含c，且b此后不再活跃

产生ADD Rj, Ri，结果a在Ri中

❖如果Ri含b，但c在内存单元，b仍然不再活跃

产生ADD c, Ri，或者产生

MOV c, Rj

ADD Rj, Ri

❖若c的值以后还要用，第二种代码较有吸引力

一个简单的代码生成器

- 在代码生成过程中，需要跟踪寄存器的内容和名字的地址
  - 寄存器描述记住每个寄存器当前存的是什么，即在任何一点，每个寄存器保存若干个(包括零个)名字的值

例：

```
                    // 语句前，R0保存变量a的值
b = a               // 不为该语句产生任何指令
                    // 语句后，R0保存变量a和b的值
```

一个简单的代码生成器

- 在代码生成过程中，需要跟踪寄存器的内容和名字的地址
  - 寄存器描述记住每个寄存器当前存的是什么，即在任何一点，每个寄存器保存若干个(包括零个)名字的值
  - 名字(变量)的地址描述记住运行时每个名字的当前值可以在哪个场所找到。这个场所可以是寄存器、栈单元、内存地址、甚至是它们的某个集合

    例：产生MOV c, R0后，c值可在R0和c的存储单元找到

一个简单的代码生成器

- 在代码生成过程中，需要跟踪寄存器的内容和名字的地址
  - 寄存器描述记住每个寄存器当前存的是什么，即在任何一点，每个寄存器保存若干个(包括零个)名字的值
  - 名字(变量)的地址描述记住运行时每个名字的当前值可以在哪个场所找到。这个场所可以是寄存器、栈单元、内存地址、甚至是它们的某个集合
  - 名字的地址信息存于符号表，另建寄存器描述表
  - 这两个描述在代码生成过程中是变化的

一个简单的代码生成器

❑寄存器选择函数

- ❖函数*getReg*返回保存x = y *op* z的x值的场所L
  - ➢如果名字y在R中，这个R不含其它名字的值,并且在执行x = y *op* z后y不再有下次引用，那么返回这个R作为L
  - ➢否则，如果有的话，返回一个空闲寄存器
  - ➢否则，如果x在块中有下次引用，或者*op*是必须用寄存器的算符，那么找一个已被占用的寄存器R(可能产生MOV R，M指令，并修改 M的描述)
  - ➢否则，如果x在基本块中不再引用，或者找不到适当的被占用寄存器，选择x的内存单元作为L

一个简单的代码生成器

❑代码生成算法

- ❖对每个三地址语句x = y *op* z
  - ➢调用函数*getReg*决定放y *op* z计算结果的场所L
  - ➢查看y的地址描述，确定y值当前的一个场所y′。如果y的值还不在L中，产生指令MOV y′，L
  - ➢产生指令*op* z′，L，其中z′是z的当前场所之一
  - ➢如果y和/或z的当前值不再引用，在块的出口也不活跃，并且还在寄存器中，那么修改寄存器描述,使得不再包含y和/或z的值

一个简单的代码生成器

- 赋值语句 $d = (a - b) + (a - c) + (a - c)$
  - 编译产生三地址语句序列：

$$t_1 = a - b$$

$$t_2 = a - c$$

$$t_3 = t_1 + t_2$$

$$d = t_3 + t_2$$

一个简单的代码生成器

语 句	生成的代码	寄存器描述	名字的地址描述
		寄存器空	
$t_1 = a - b$			
$t_2 = a - c$			
$t_3 = t_1 + t_2$			
$d = t_3 + t_2$			

一个简单的代码生成器

语 句	生成的代码	寄存器描述	名字的地址描述
		寄存器空	
$t_1 = a - b$	MOV a, R0 SUB b, R0	R0含t_1	t_1在R0中
$t_2 = a - c$			
$t_3 = t_1 + t_2$			
$d = t_3 + t_2$			

一个简单的代码生成器

语 句	生成的代码	寄存器描述	名字的地址描述
		寄存器空	
$t_1 = a - b$	MOV a, R0 SUB b, R0	R0含t_1	t_1在R0中
$t_2 = a - c$	MOV a, R1 SUB c, R1	R0含t_1 R1含t_2	t_1在R0中 t_2在R1中
$t_3 = t_1 + t_2$			
$d = t_3 + t_2$			

一个简单的代码生成器

语 句	生成的代码	寄存器描述	名字的地址描述
		寄存器空	
$t_1 = a - b$	MOV a, R0 SUB b, R0	R0含t_1	t_1在R0中
$t_2 = a - c$	MOV a, R1 SUB c, R1	R0含t_1 R1含t_2	t_1在R0中 t_2在R1中
$t_3 = t_1 + t_2$	ADD R1,R0	R0含t_3 R1含t_2	t_3在R0中 t_2在R1中
$d = t_3 + t_2$			

一个简单的代码生成器

语 句	生成的代码	寄存器描述	名字的地址描述
		寄存器空	
$t_1 = a - b$	MOV a, R0 SUB b, R0	R0含t_1	t_1在R0中
$t_2 = a - c$	MOV a, R1 SUB c, R1	R0含t_1 R1含t_2	t_1在R0中 t_2在R1中
$t_3 = t_1 + t_2$	ADD R1,R0	R0含t_3 R1含t_2	t_3在R0中 t_2在R1中
$d = t_3 + t_2$	ADD R1,R0	R0含d	d在R0中
	MOV R0, d		d在R0和内存中

一个简单的代码生成器

- 前三条指令可以修改，使执行代价降低

修改前	修改后
MOV a, R0	MOV a, R0
SUB b, R0	MOV R0, R1
MOV a, R1	SUB b, R0
SUB c, R1	SUB c, R1
. . .	. . .

一个简单的代码生成器

❑为特殊语句产生代码

❖变址和指针语句

- ➢变址与指针运算的三地址语句的处理和二元算符的处理相同

语句	i在寄存器Ri中		i在内存Mi中		i在栈中	
	代码	代价	代码	代价	代码	代价
a = b[i]	MOV b(Ri), R	2	MOV Mi, R MOV b(R), R	4	MOV Si(Rs), R MOV b(R), R	4
b[i] = a	MOV a, b(Ri)	3	MOV Mi, R MOV a, b(R)	5	MOV Si(Rs), R MOV a, b(R)	5

一个简单的代码生成器

- 为特殊语句产生代码
  - 变址和指针语句
    - 变址与指针运算的三地址语句的处理和二元算符的处理相同
  - 条件语句
    - 根据寄存器的值是否为下面六个条件之一进行分支：负、零、正、非负、非零和非正
    - 用条件码来表示计算的结果或装入寄存器的值是负、零还是正

一个简单的代码生成器

1、根据寄存器的值是否为下面六个条件之一进行分支：负、零、正、非负、非零和非正

- 例 if x < y goto z
  - 把x减y的值存入寄存器R
  - 如果R的值为负，则跳到z

一个简单的代码生成器

2、用条件码的例子

❑例：若if x < y goto z

的实现是：

```
CMP   x,     y
CJ<   z
```

则：x = y + w

if x < 0 goto z

的实现是：

```
MOV   y,   R0
ADD   w,   R0
MOV   R0,  x
CJ<   z
```

本章小结

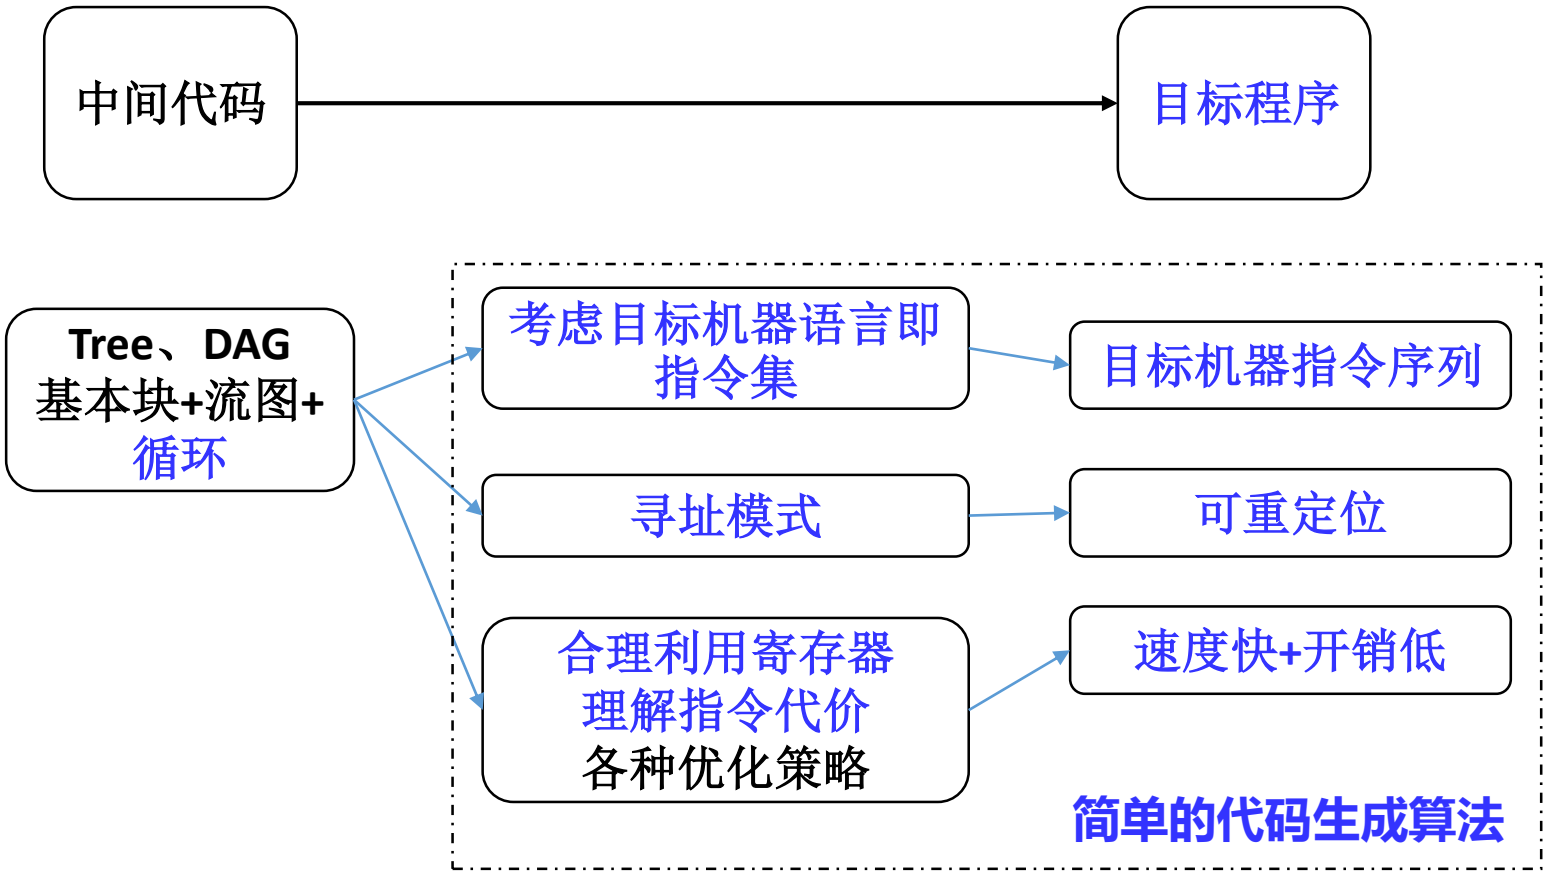
中间代码
目标程序
Tree、DAG
基本块+流图+
循环
考虑目标机器语言即
指令集
目标机器指令序列
寻址模式
可重定位
合理利用寄存器
理解指令代价
各种优化策略
速度快+开销低
简单的代码生成算法

中国科学技术大学
University of Science and Technology of China

USTC, CHINA
ADSLAB
先进数据系统实验室

《编译原理与技术》
代码生成

The hardest part of the software task is arriving at a complete and consistent specification, and much of the essence of building a program is in fact the debugging of the specification.

—— Fred Brooks (Turing Award 1999)