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》
中间代码生成 I

计算机科学与技术学院
李 诚
12/11/2018

关于课程实验

- 目标：为PL0语言实现一个简单的编译器
  - **Project 1：** 词法分析
  - **Project 2：** 语法分析
  - **Project 3：** 语法错误处理+对前两个project的扩展，11.15 release，11.30提交
  - **Project 4：** 代码生成，12.1 release，12.15提交
  - 项目结束后，需要进行答辩，每一组准备ppt，每一名同学都要汇报
    - 自己做了什么
    - 学到了什么
    - 对课程和实验的意见与建议

通知

- 期中考试的成绩在本周之内公布。
- 由于老师出差，周四的课取消，后面补回来。
- 周四的上机课正常进行，助教会发布新的项目内容，并对之前项目的完成情况进行说明，请大家尽量都去。

主要内容

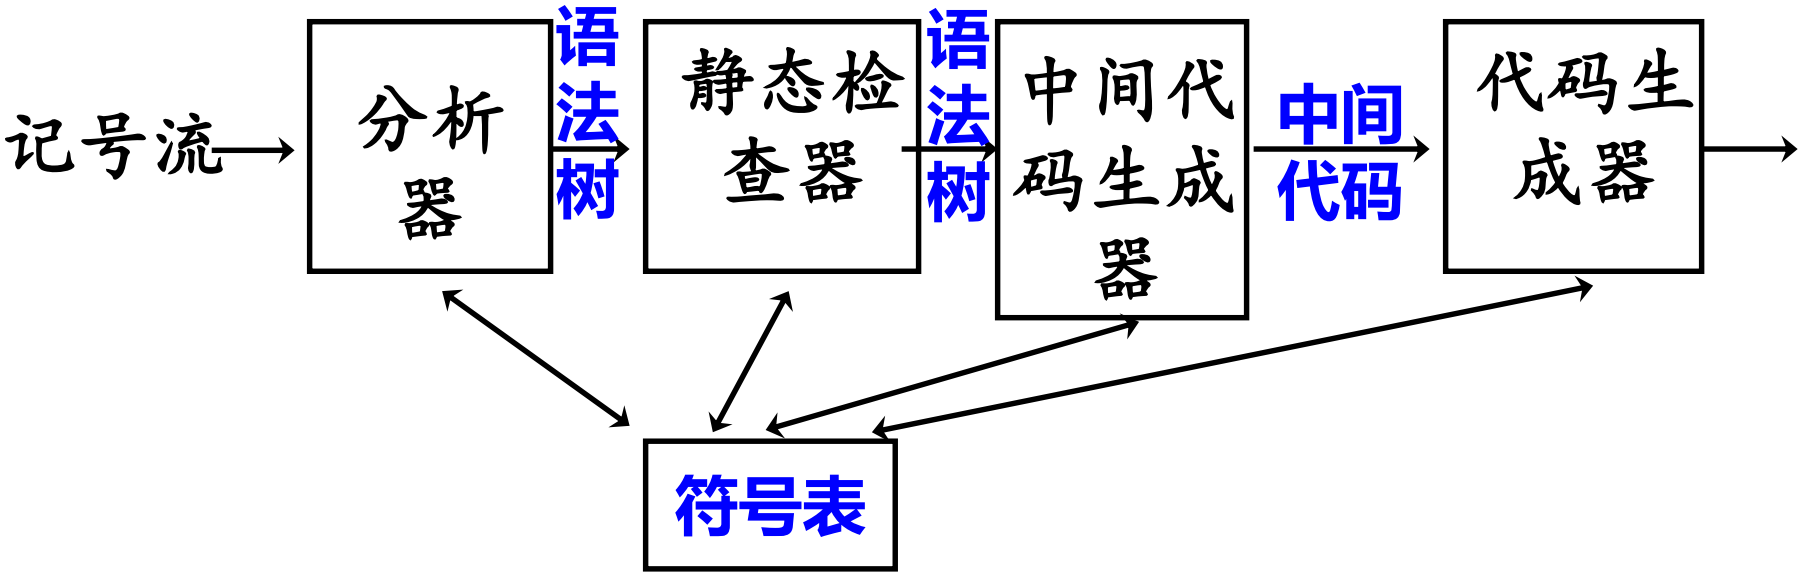

- **中间语言(Intermediate Representation)**
  - 后缀表达式、图表示、三地址码、静态单赋值
- **中间代码生成**
  - 声明语句(更新符号表)
  - 表达式、赋值语句(产生临时变量、查询符号表)
  - 布尔表达式、控制流语句(标号/回填、短路计算)

主要内容

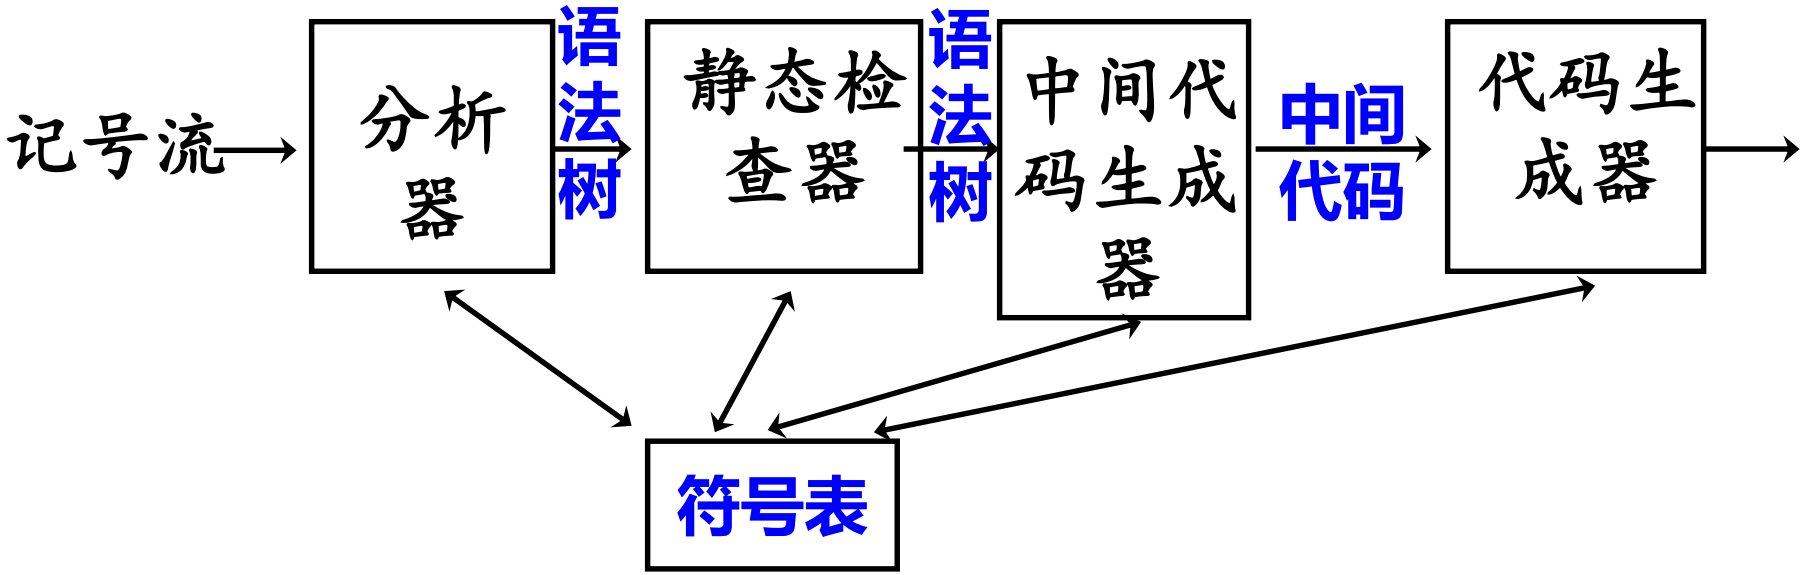

- **中间语言(Intermediate Representation)**
  - 后缀表达式、图表示、三地址码、静态单赋值
- **中间代码生成**
  - 声明语句(更新符号表)
  - 表达式、赋值语句(产生临时变量、查询符号表)
  - 布尔表达式、控制流语句(标号/回填、短路计算)

为什么需要中间语言?

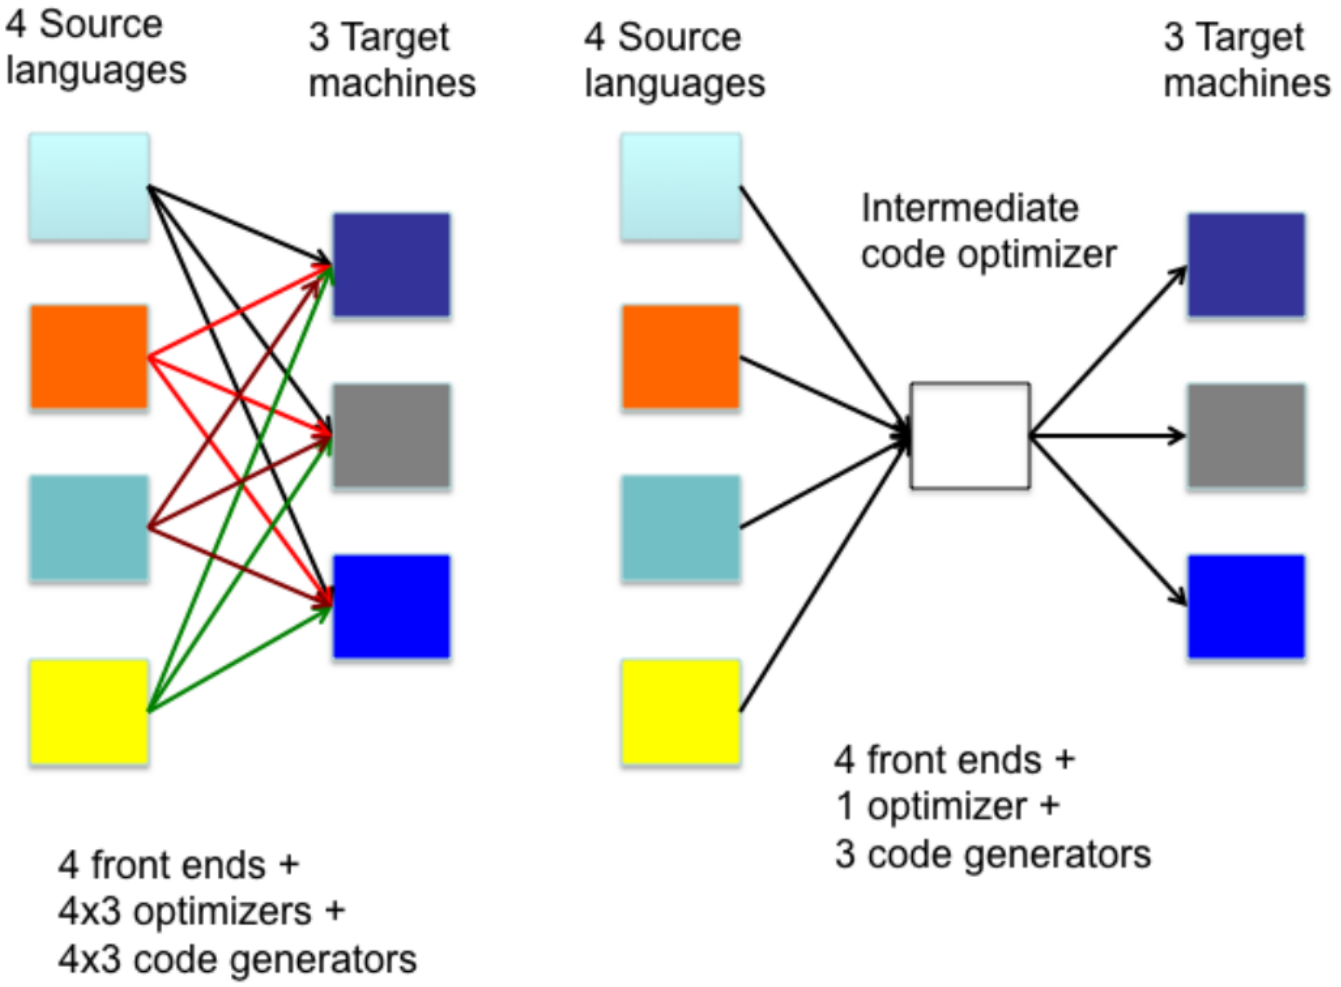

实践过程中，推陈出新的语言、不断涌现的指令集、开发成本之间的权衡

后缀表示

*uop*是一元运算符

$$E \rightarrow E\ opE \mid uopE \mid (E) \mid \mathbf{id} \mid \mathbf{num}$$

表达式E	后缀式E'
id	id
num	num
$E_1\ op\ E_2$	$E_1'\ E_2'\ op$
$uopE$	$E'uop$
(E)	E'

后缀表示

- 后缀表示不需要括号
  - (8 – 5) + 2 的后缀表示是8 5 –2 +
- 后缀表示的最大优点是便于计算机处理表达式

计算栈	输入串
	8 5 –2 +
8	5 –2 +
8 5	–2 +
3	2 +
3 2	+
5	

后缀表示

- 后缀表示不需要括号
  - (8 – 5) + 2 的后缀表示是8 5 –2 +
- 后缀表示的最大优点是便于计算机处理表达式
- 后缀表示的表达能力
  - 可以拓广到表示赋值语句和控制语句
  - 但很难用栈来描述控制语句的计算

- 语法树是一种图形化的中间表示

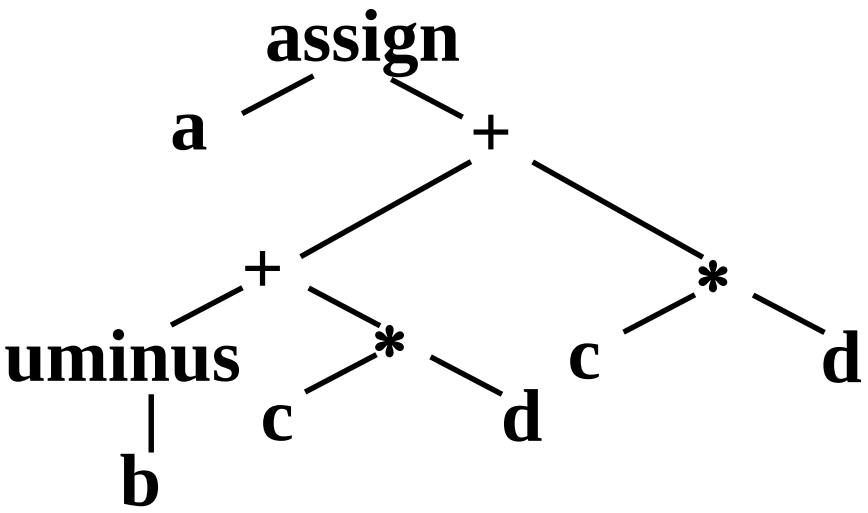

(a) 语法树

a = (–b + c*d) + c*d的图形表示

图形表示

- 语法树是一种图形化的中间表示

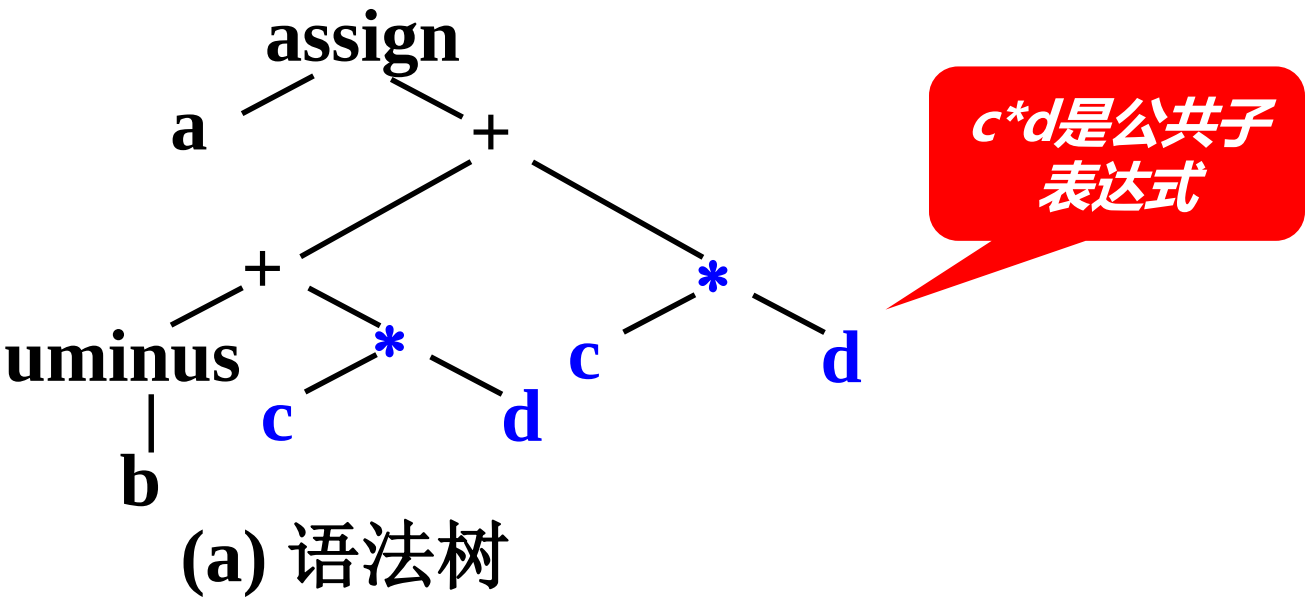

(a) 语法树

a = (–b + c*d) + c*d的图形表示

图形表示

- 语法树是一种图形化的中间表示
- 有向无环图(Directed Acyclic Graph, DAG)也是一种中间表示

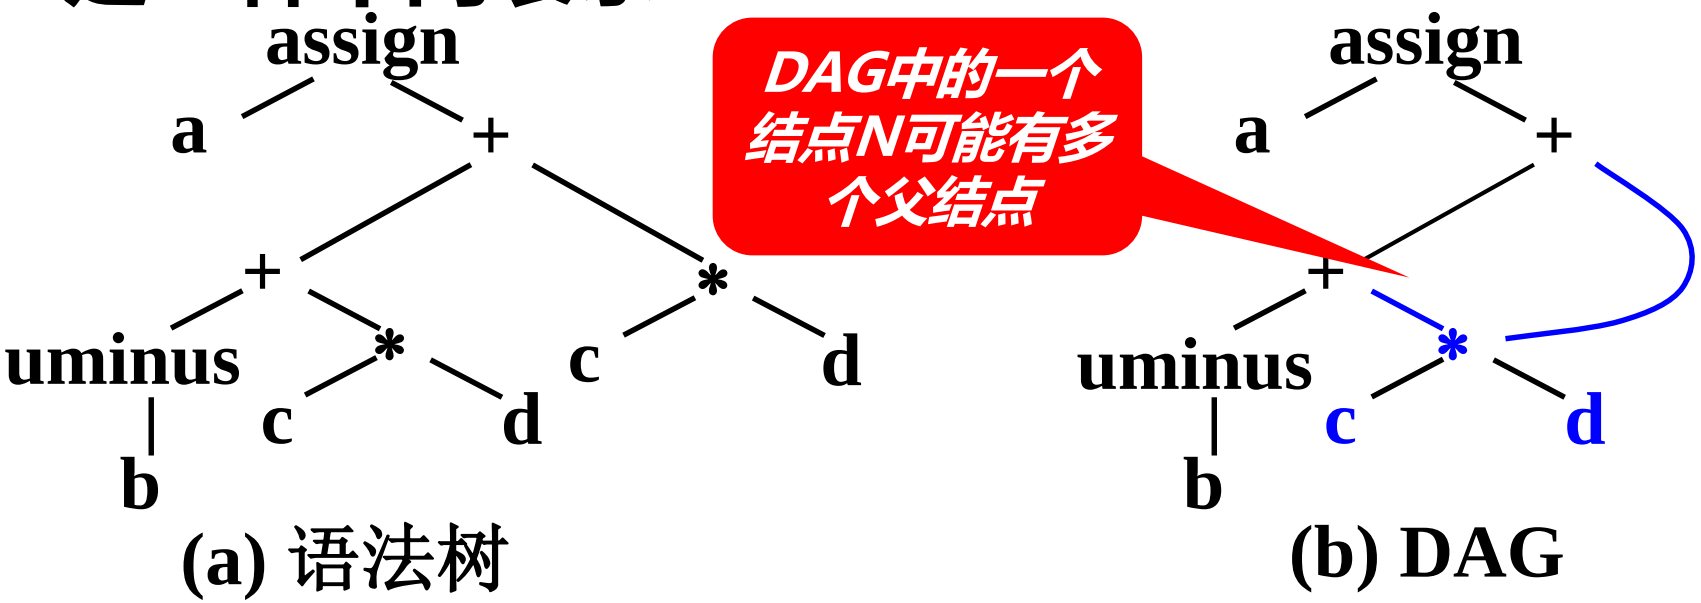

(a) 语法树　　(b) DAG

a = (–b + c*d) + c*d的图形表示

构造赋值语句语法树的语法制导定义(第四章内容)

修改构造结点的函数可生成有向无环图

产 生 式	语 义 规 则
$S \rightarrow \text{id} = E$	$S.nptr = mkNode(\text{'assign'}, mkLeaf(\text{id}, \text{id}.entry), E.nptr)$
$E \rightarrow E_1 + E_2$	$E.nptr = mkNode(\text{'+'}, E_1.nptr, E_2.nptr)$
$E \rightarrow E_1 * E_2$	$E.nptr = mkNode(\text{'*'}, E_1.nptr, E_2.nptr)$
$E \rightarrow -E_1$	$E.nptr = mkUNode(\text{'uminus'}, E_1.nptr)$
$E \rightarrow (E_1)$	$E.nptr = E_1.nptr$
$F \rightarrow \text{id}$	$E.nptr = mkLeaf(\text{id}, \text{id}.entry)$

❑三地址代码 (three-address code)

一般形式：$x = y\ op\ z$

- 最多一个算符
- 最多三个计算分量
- 每一个分量代表一个地址，因此三地址

❑ 例 表达式$x + y * z$翻译成的三地址语句序列

$t_1 = y * z$

$t_2 = x + t_1$

❑三地址代码是语法树或DAG的一种线性表示

❖例　　a = (–b + c*d) + c*d

语法树的代码

$t_1 = -b$

$t_2 = c * d$

$t_3 = t_1 + t_2$

$t_4 = c * d$

$t_5 = t_3 + t_4$

$a = t_5$

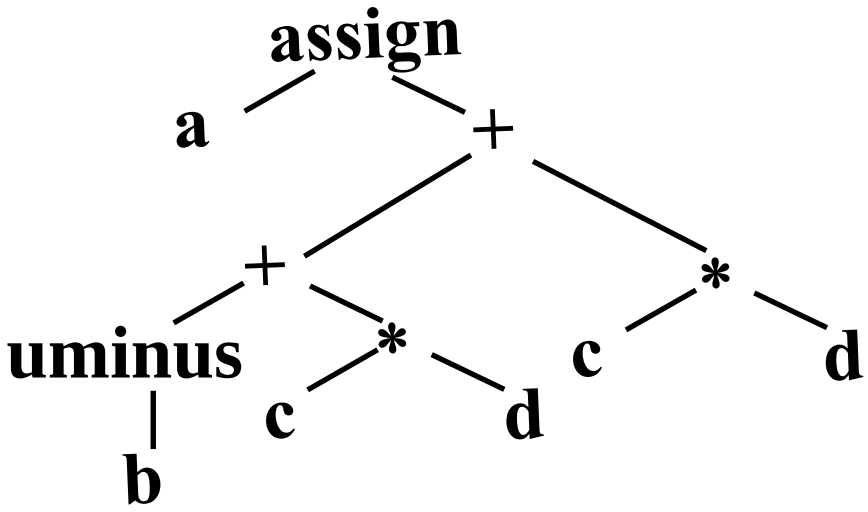

❑三地址代码是语法树或DAG的一种线性表示

❖例　　a = (–b + c*d) + c*d

语法树的代码

$t_1 = -b$

$t_2 = c * d$

$t_3 = t_1 + t_2$

$t_4 = c * d$

$t_5 = t_3 + t_4$

$a = t_5$

DAG的代码

$t_1 = -b$

$t_2 = c * d$

$t_3 = t_1 + t_2$

$t_4 = t_3 + t_2$

$a = t_4$

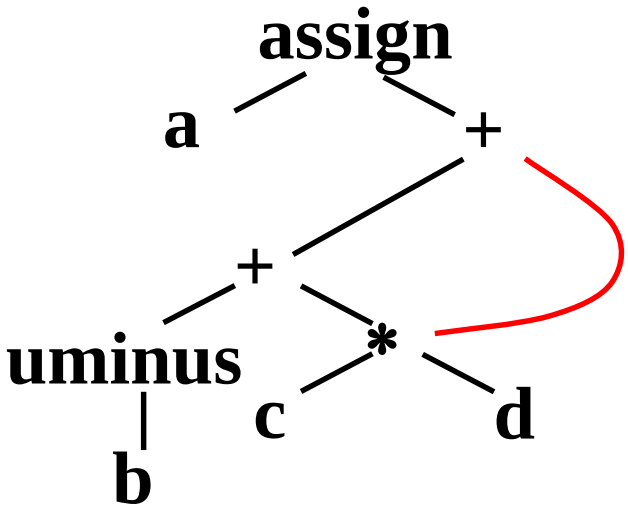

❑常用的三地址语句

- ❖赋值语句 $x = y\ op\ z$， $x = op\ y$， $x = y$
- ❖无条件转移 **goto L**
- ❖条件转移 **if** $x\ relop\ y$ **goto L**
- ❖过程调用 **param** x 和 **call p ,** n
- ❖过程返回 **return** y
- ❖索引赋值 $x = y[i]$ 和 $x[i] = y$
- ❖地址和指针赋值 $x = \&y$， $x = *y$ 和 $*x = y$

三地址代码的实现方式

- 三地址代码只说明了指令的组成部分，为描述其在编译器中的具体数据结构实现
- 常见的实现方式有三种：
  - 四元式：(op, arg1, arg2, result)
  - 三元式：(op, arg1, arg2)
  - 间接三元式：(三元式的指针表)

三地址代码的实现方式

❑四元式(Quadruple)

❖例： a = b * – c + b * – c

#	Op	Arg1	Arg2	Result
(0)	uminus	c		t1
(1)	*	t1	b	t2
(2)	uminus	c		t3
(3)	*	t3	b	t5
(4)	+	t2	t4	t5
(5)	=	t5		a

缺点：临时变量太多，增加时间和空间成本

三地址代码的实现方式

❑三元式(Triple)

❖例： a = b * – c + b * – c

#	Op	Arg1	Arg2
(0)	uminus	c	
(1)	*	(0)	b
(2)	uminus	c	
(3)	*	(2)	b
(4)	+	(1)	(3)
(5)	=	a	(4)

缺点：隐式的临时变量，代码位置调整会造成引用该位置的代码也要修改。

三地址代码的实现方式

❑间接三元式(Indirect triple)

❖例： a = b * – c + b * – c

指令序列可以任意调整顺序

List of pointers to table

#	Op	Arg1	Arg2
(14)	+	x	y
(15)	+	y	z
(16)	*	(14)	(15)
(17)	+	(14)	z
(18)	+	(16)	(17)

#	Statement
(1)	(14)
(2)	(15)
(3)	(16)
(4)	(17)
(5)	(18)

优势：比四元式空间开销小，比三元式更灵活

三地址代码的实现方式总结

四元式	按编号次序计算	计算结果存于**result**	方便移动，计算次序容易调整	大量引入临时变量
三元式	按编号次序计算	由编号代表	不方便移动	在代码生成时进行临时变量的分配
间接三元式	按编号次序计算		方便移动，计算次序容易调整	在代码生成时进行临时变量的分配

静态单赋值形式

- 一种便于某些代码优化的中间表示
- 和三地址代码的主要区别
  - 所有赋值指令都是对不同名字的变量的赋值

三地址代码	静态单赋值形式
$p = a + b$	$p_1 = a + b$
$q = p - c$	$q_1 = p_1 - c$
$p = q * d$	$p_2 = q_1 * d$
$p = e - p$	$p_3 = e - p_2$
$q = p + q$	$q_2 = p_3 + q_1$

静态单赋值形式

- 一种便于某些代码优化的中间表示
- 和三地址代码的主要区别
  - 所有赋值指令都是对不同名字的变量的赋值
  - 一个变量在不同路径上都定值的解决办法

```
if (flag) x = –1; else x = 1;
y = x * a;
```

改成

```
if (flag) x1 = –1; else x2 = 1;
x3 = φ(x1, x2);      //由flag的值决定用x1还是x2
```

主要内容

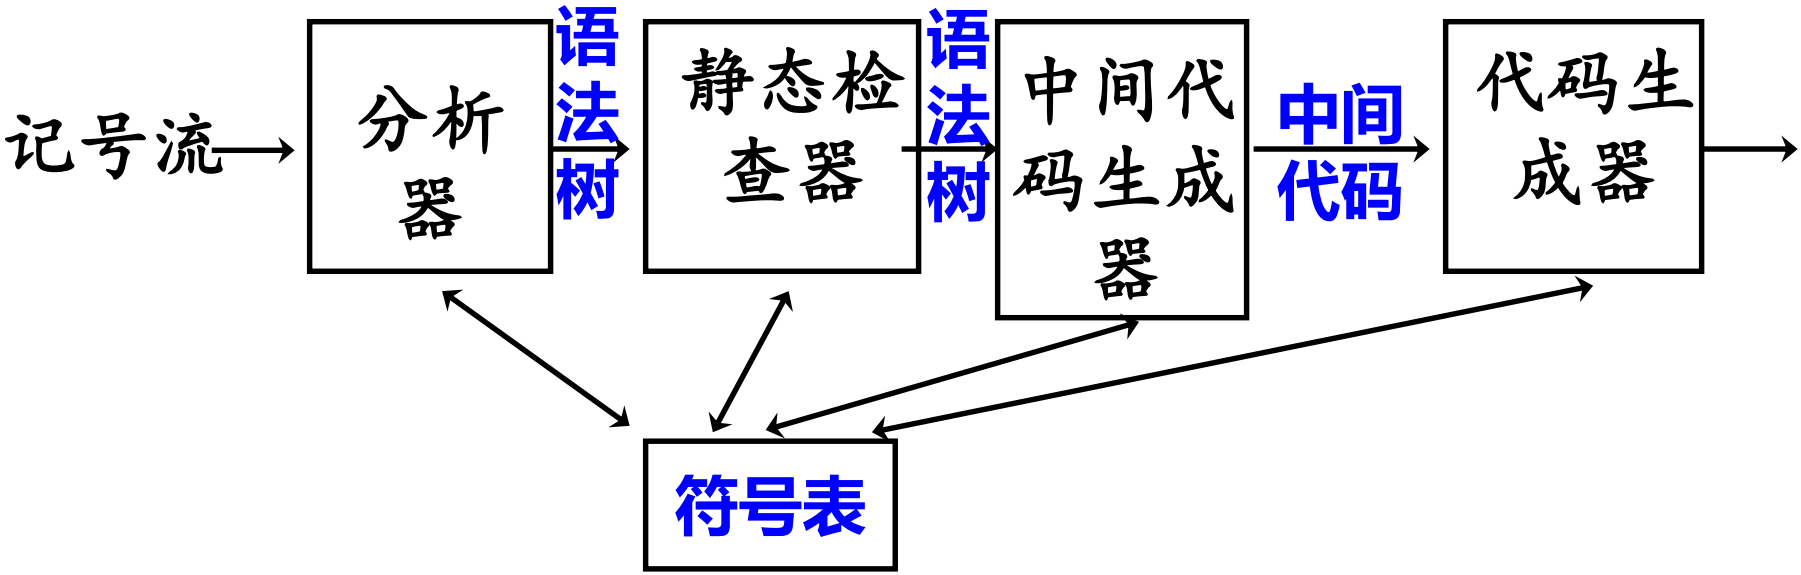

- 中间语言(Intermediate Representation)
  - 后缀表达式、图表示、三地址码、静态单赋值
- 中间代码生成
  - 声明语句(更新符号表)
  - 表达式、赋值语句(产生临时变量、查询符号表)
  - 布尔表达式、控制流语句(标号/回填、短路计算)

中间代码生成的关键问题

❑ 类型与符号表的变化

- ❖多样化类型 => 整型(字节、字)、浮点型、类型符号表
- ❖1个某类型的数据 => m 个字节(m为类型对应的字宽)

❑语句的翻译

- ❖声明语句：不生成指令，但会更新符号表(作用域， 字宽及存放的相对地址)
- ❖赋值语句：引入临时变量、数组/记录元素的地址计算、类型转换
- ❖控制流语句：跳转目标的确定(引入标号或使用回填技术)、短路计算

符号表的设计

❑类型检查后的符号表

- ❖符号表条目：(标识符、存储类别、类型信息)
- ❖存储类别：**extern, static, register, …**
- ❖类型信息：(类别标识, 该类别关联的其他信息)
  - ➢如数组**(array(len, elemtype))**

❑本章符号表的变化

- ❖作用域 =>多个符号表
- ❖变量：字宽、存储的相对地址(以字节为单位)
- ❖记录类型：用符号表管理各个成员的字宽、相对地址

中间代码生成的方法

- 边解析边生成中间代码
  - 语法制导的翻译方案
  - 难点：理解分析器的运转机制、继承属性的处理
- 基于树访问的中间代码生成
  - 重点：树结构的设计、访问者模式、enter/exit接口及 实现

本节将以基于树访问的中间代码生成方法为主来讲解， 这是现代编译器使用的主流方法。

主要内容

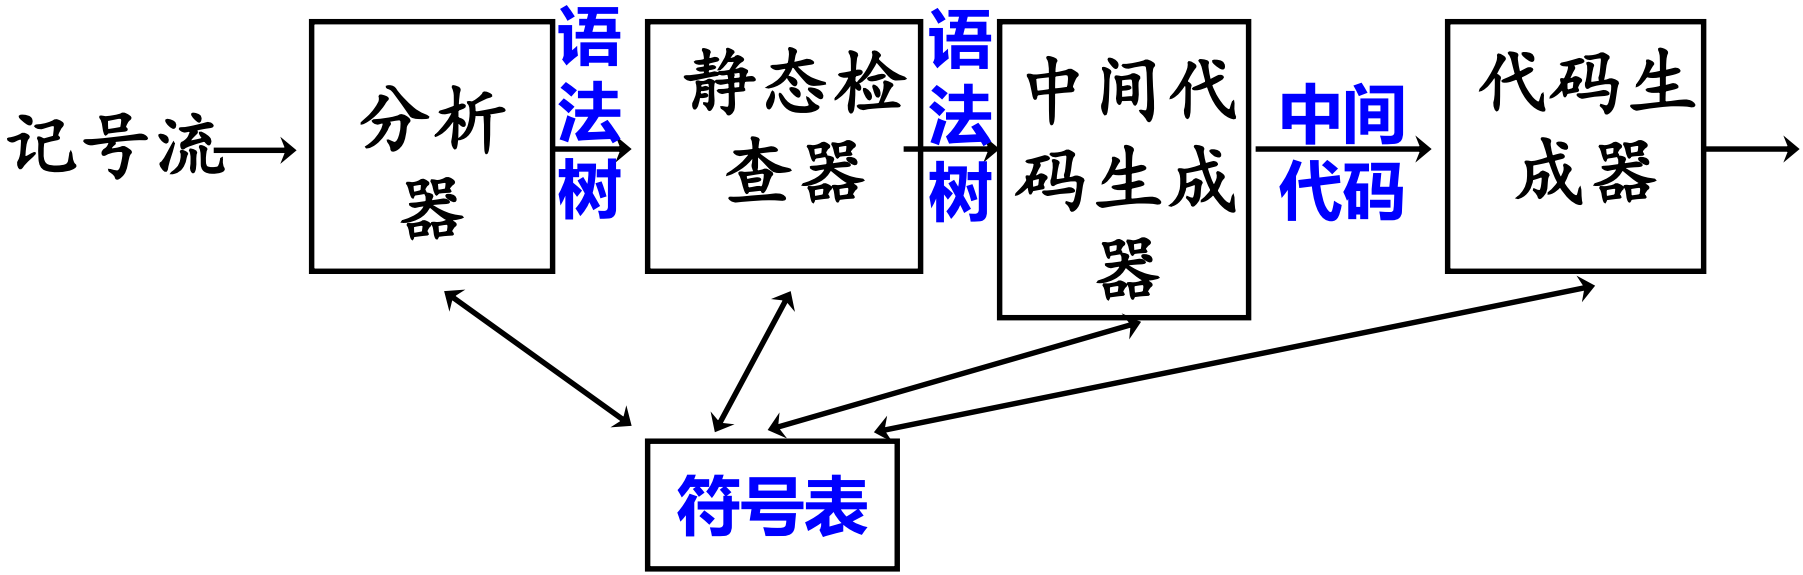

- 中间语言(Intermediate Representation)
  - 后缀表达式、图表示、三地址码、静态单赋值
- 中间代码生成
  - 声明语句(更新符号表)
  - 表达式、赋值语句(产生临时变量、查询符号表)
  - 布尔表达式、控制流语句(标号/回填、短路计算)

声明语句

❑知识要点

- ❖分配存储单元
- ❖更新符号表
- ❖作用域的管理
- ❖记录类型的管理

声明语句的翻译

❑ 主要任务

- ❖为局部名字分配存储单元 符号表条目：
  - ➢名字、类型、字宽、偏移
- ❖作用域信息的保存
  - ➢过程调用
- ❖记录类型的管理

不产生中间代码指令，但是要更新符号表

声明语句的翻译

- 例：文法G_1如下：

$P \rightarrow D ; S$

$D \rightarrow D ; D$

$D \rightarrow id : T$

$T \rightarrow integer \mid real \mid array [num] of T_1 \mid \uparrow T_1$

声明语句的翻译

❑ 有关符号的属性

T.type - 变量所具有的类型，如

整型 INT

实型 REAL

数组类型 array（元素个数，元素类型）

指针类型 pointer（所指对象类型）

T.width - 该类型数据所占的字节数

offset - 变量的存储偏移地址

声明语句的翻译

T.type		T.width
整型	INT	4
实型	REAL	8
数组	array（num, T_1）	num.val * T_1.width
指针	pointer（T_1）	4
enter(name, type, offset)—将类型type和偏移offset填入符号表中name所在的表项。		

声明语句的翻译

计算被声明名字的类型和相对地址

P→ {*offset = 0*} D ; S

相对地址初始化为0

D→ D ; D

D→ id : T {*enter(* id.*lexeme, T.type, offset) ;*

offset = offset + T.width }

更新符号表信息

T→integer {*T.type = integer; T.width = 4*}

T→real {*T.type = real; T.width = 8*}

类型=>字宽

T→array [number] of T_1

{*T.type = array(num.val,* T_1*.type);*

*T.width = num.val * *T_1*.width*}

T→ ↑ T_1 {*T.type = pointer(*T_1*.type); T.width = 4*}

允许自定义过程时的翻译

- 所讨论语言的文法

$P \rightarrow D; S$

$D \rightarrow D\ ;\ D \mid \text{id} : T \mid$

proc id ; D ; S

- 管理作用域(过程嵌套声明)
  - 每个过程内声明的符号要置于该过程的符号表中
  - 方便地找到子过程和父过程对应的符号

```
sort
    var a:…; x:…;
    readarray
        var i:…;
    exchange
    quicksort
        var k, v:…;
        partition
            var i, j:…;
```

教科书186页图6.14

过程参数被略去

各过程的符号表

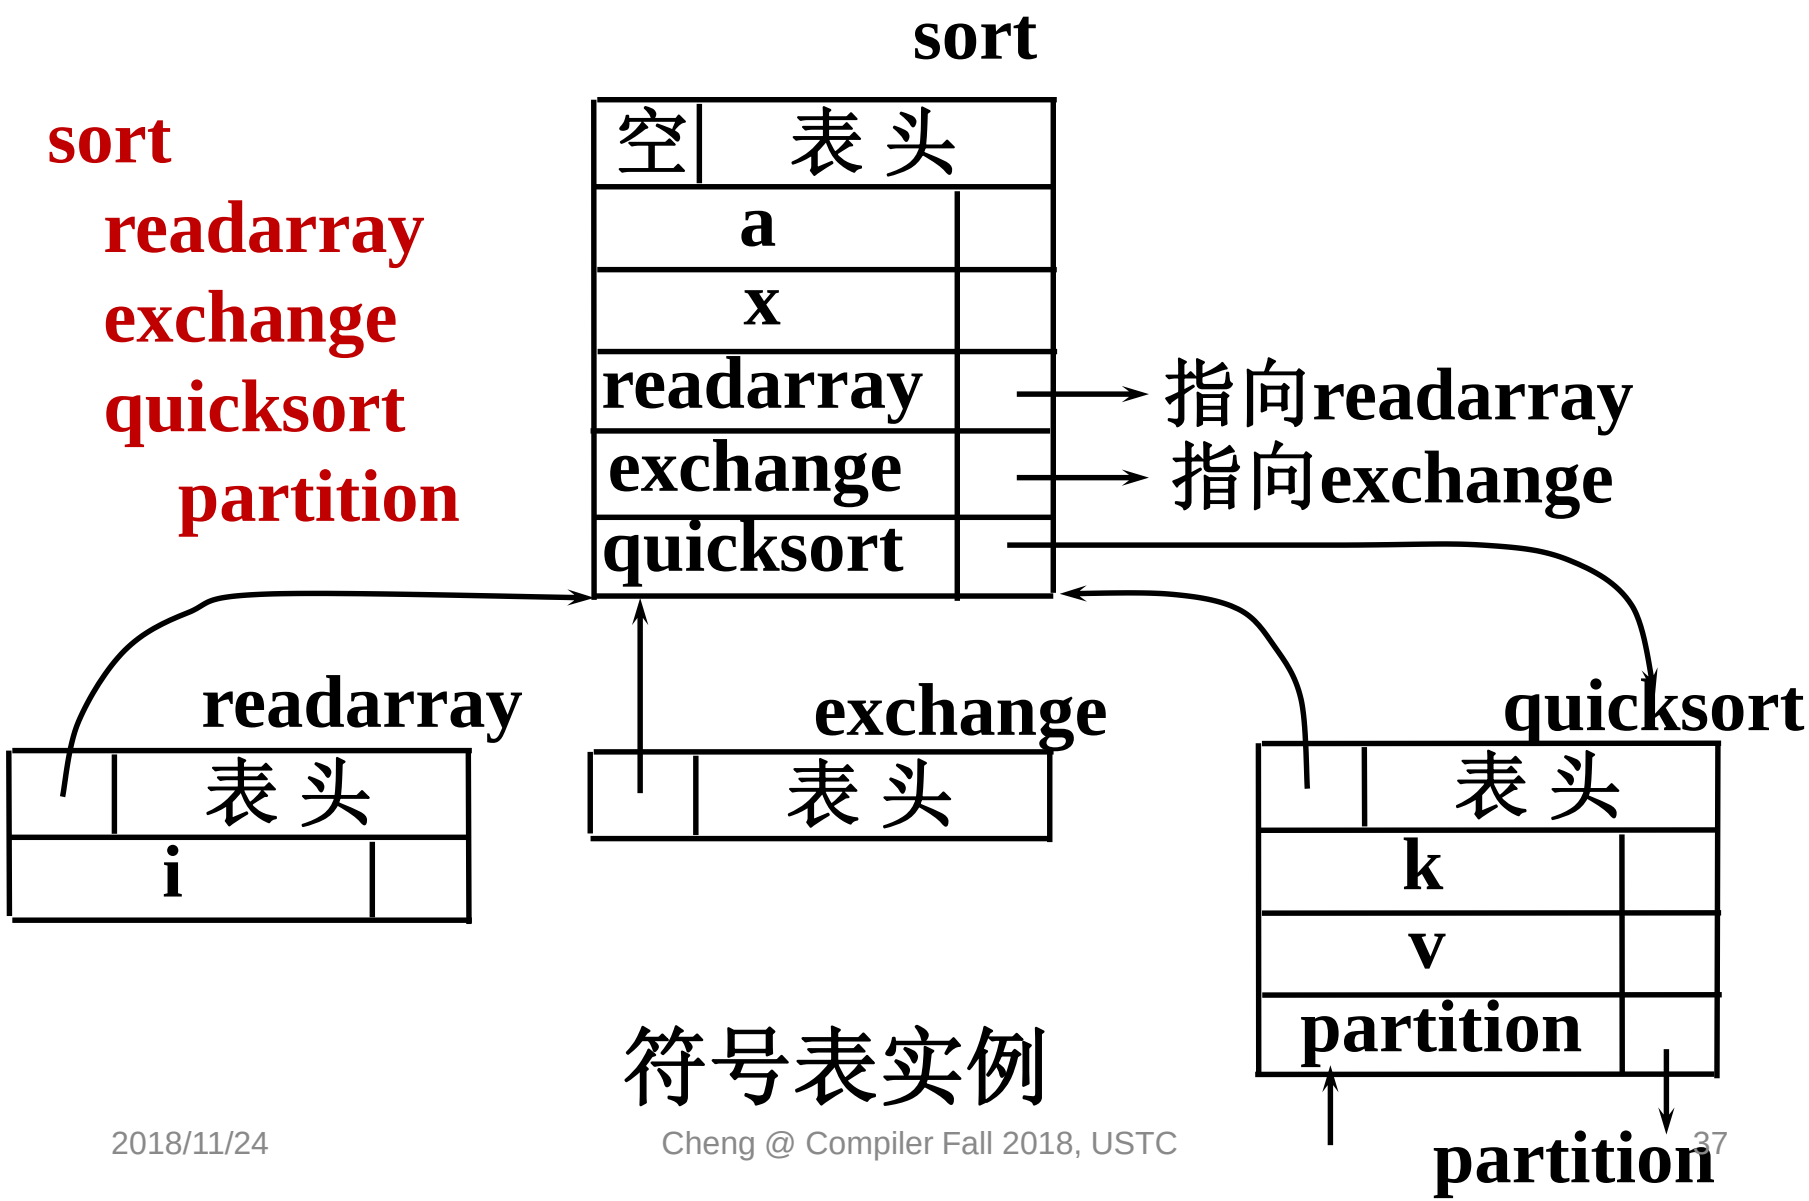

符号表实例

❑符号表的特点及数据结构

- ❖各过程有各自的符号表：哈希表
- ❖符号表之间有双向链
  - ➢父→子：过程中包含哪些子过程定义
  - ➢子→父：分析完子过程后继续分析父过程
- ❖维护符号表栈(*tblptr*)和地址偏移量栈(*offset*)
  - ➢保存尚未完成的过程的符号表指针和相对地址

❑语义动作用到的函数

/* 在父过程符号表中建立子过程名的条目*/

1. enterProc(parent-table, sub-proc-name, sub-table)

/* 建立新的符号表，其表头指针指向父过程符号表*/

2. mkTable(parent-table)

/* 将所声明变量的类型、偏移填入当前符号表*/

3. enter(current-table, name, type, current-offset)

/*为符号表添加变量累加宽度，符号表栈tblptr和偏移栈offset（栈顶值分别表示当前分析的过程的符号表及可用变量偏移位置）*/

4. addWidth(table, width)

声明语句的处理

$P \rightarrow M\ D;\ S$

$M \rightarrow \varepsilon$

$D \rightarrow D_1\ ;\ D_2$

$D \rightarrow \text{proc id}\ ;\ N\ D_1;\ S$

$D \rightarrow \text{id}\ :T$

$N \rightarrow \varepsilon$

声明语句的处理

tblptr：符号表栈
offset：偏移量栈

$P \rightarrow M\ D;\ S$

$M \rightarrow \varepsilon$ {*t = mkTable (nil);*
push(t, tblptr); push (0, offset) }

$D \rightarrow D_1\ ;\ D_2$

$D \rightarrow$ proc id ; $N\ D_1;\ S$

$D \rightarrow$ id $:T$

$N \rightarrow \varepsilon$

建立主程序（最外围）的符号表偏移从0开始

声明语句的处理

$P \rightarrow M\ D;\ S$

$M \rightarrow \varepsilon$ {*t = mkTable (nil);*
push(t, tblptr); push (0, offset) }

$D \rightarrow D_1\ ;\ D_2$

$D \rightarrow$ proc id ; $N\ D_1;\ S$

$D \rightarrow$ id : T {*enter(top(tblptr),* id.*lexeme, T.type, top(offset));*
top(offset) = top(offset) + T.width }

$N \rightarrow \varepsilon$

将变量name的有关属性填入当前符号表

声明语句的处理

$P \rightarrow M\ D;\ S$

$M \rightarrow \varepsilon$ {*t = mkTable (nil);*
push(t, tblptr); push (0, offset) }

$D \rightarrow D_1\ ;\ D_2$

$D \rightarrow$ proc id ; $N\ D_1;\ S$

$D \rightarrow$ id :T {*enter(top(tblptr),* id.*lexeme, T.type, top(offset));*
top(offset) = top(offset) + T.width }

$N \rightarrow \varepsilon$ {*t = mkTable(top(tblptr));*
push(t, tblptr); push(0, offset) }

建立子过程的符号表和偏移从0开始

声明语句的处理

$P \rightarrow M\ D;\ S$

$M \rightarrow \varepsilon$ {*t = mkTable (nil);*
push(t, tblptr); push (0, offset) }

$D \rightarrow D_1\ ;\ D_2$

$D \rightarrow$ proc id ; $N\ D_1;\ S$ {*t = top(tblptr);*
addWidth(t, top(offset)); pop(tblptr); pop(offset);
enterProc(top(tblptr), id.lexeme, t) }

$D \rightarrow$ id :T {*enter(top(tblptr), id.lexeme, T.type, top(offset));*
top(offset) = top(offset) + T.width }

$N \rightarrow \varepsilon$ {*t = mkTable(top(tblptr));*
push(t, tblptr); push(0, offset) }

保留当前过程声明的总空间；弹出符号表和偏移栈顶（露出父过程的符号表和偏移；在父过程符号表中填写子过程名有关条目

声明语句的处理

$P \rightarrow M\ D;\ S$ {*addWidth (top (tblptr), top (offset));*
pop(tblptr); pop (offset) }

$M \rightarrow \varepsilon$ {*t = mkTable (nil);*
push(t, tblptr); push (0, offset) }

$D \rightarrow D_1\ ;\ D_2$

$D \rightarrow$ proc id ; $N\ D_1;\ S$ {*t = top(tblptr);*
addWidth(t, top(offset)); pop(tblptr); pop(offset);
enterProc(top(tblptr), id.*lexeme, t)* }

$D \rightarrow$ id :T {*enter(top(tblptr),* id.*lexeme, T.type, top(offset));*
top(offset) = top(offset) + T.width }

$N \rightarrow \varepsilon$ {*t = mkTable(top(tblptr));*
push(t, tblptr); push(0, offset) }

修改变量分配空间大小并清空符号表和偏移栈

举例：过程嵌套声明


```
i : int;  j : int ;
PROC P1 ;
   k : int;  f : real ;
   PROC P2;
          l : int ;
         a1 ;
   a2;
PROC P3;
   temp : int ;  max : int ;
   a3;
```

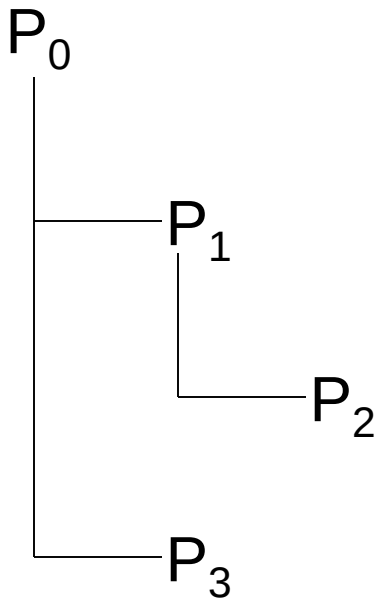

过程声明层次图

举例：过程嵌套声明

❑初始：M→ε

null	总偏移：

P_0

top → | P_0 | 0 |

符号栈　偏移栈

举例：过程嵌套声明

- i : int ; j : int ;

null	总偏移：		P_0
i	INT	0	
j	INT	4	

举例：过程嵌套声明

- PROC P_1；（N→ε）

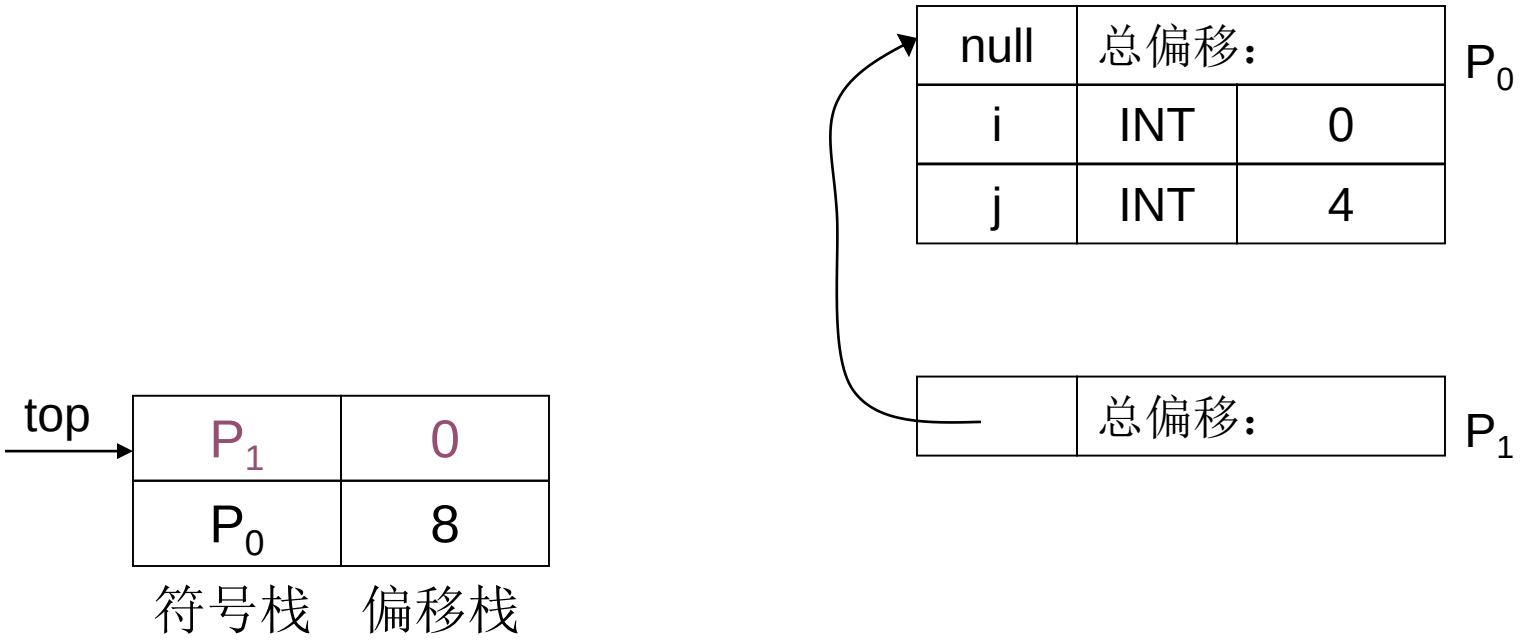

举例：过程嵌套声明

- k : int ; f : real ;

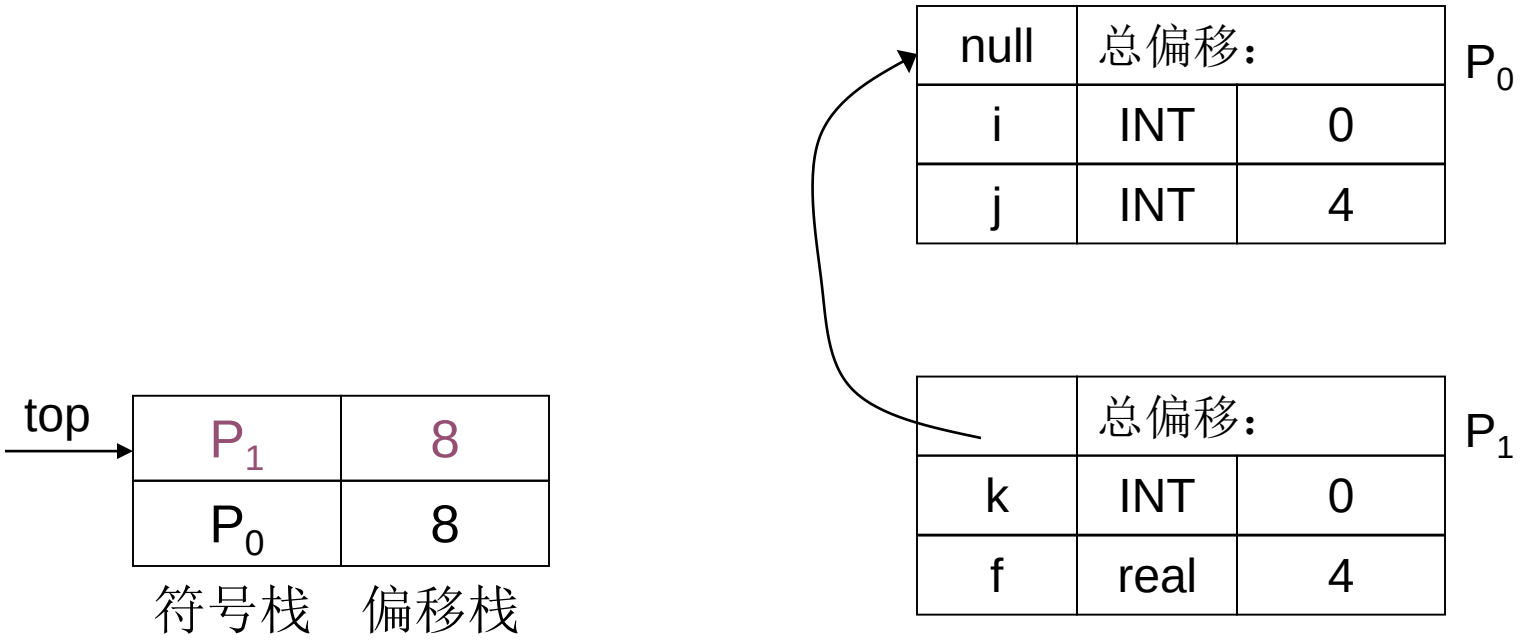

举例：过程嵌套声明

- PROC P_2；（N→ε）

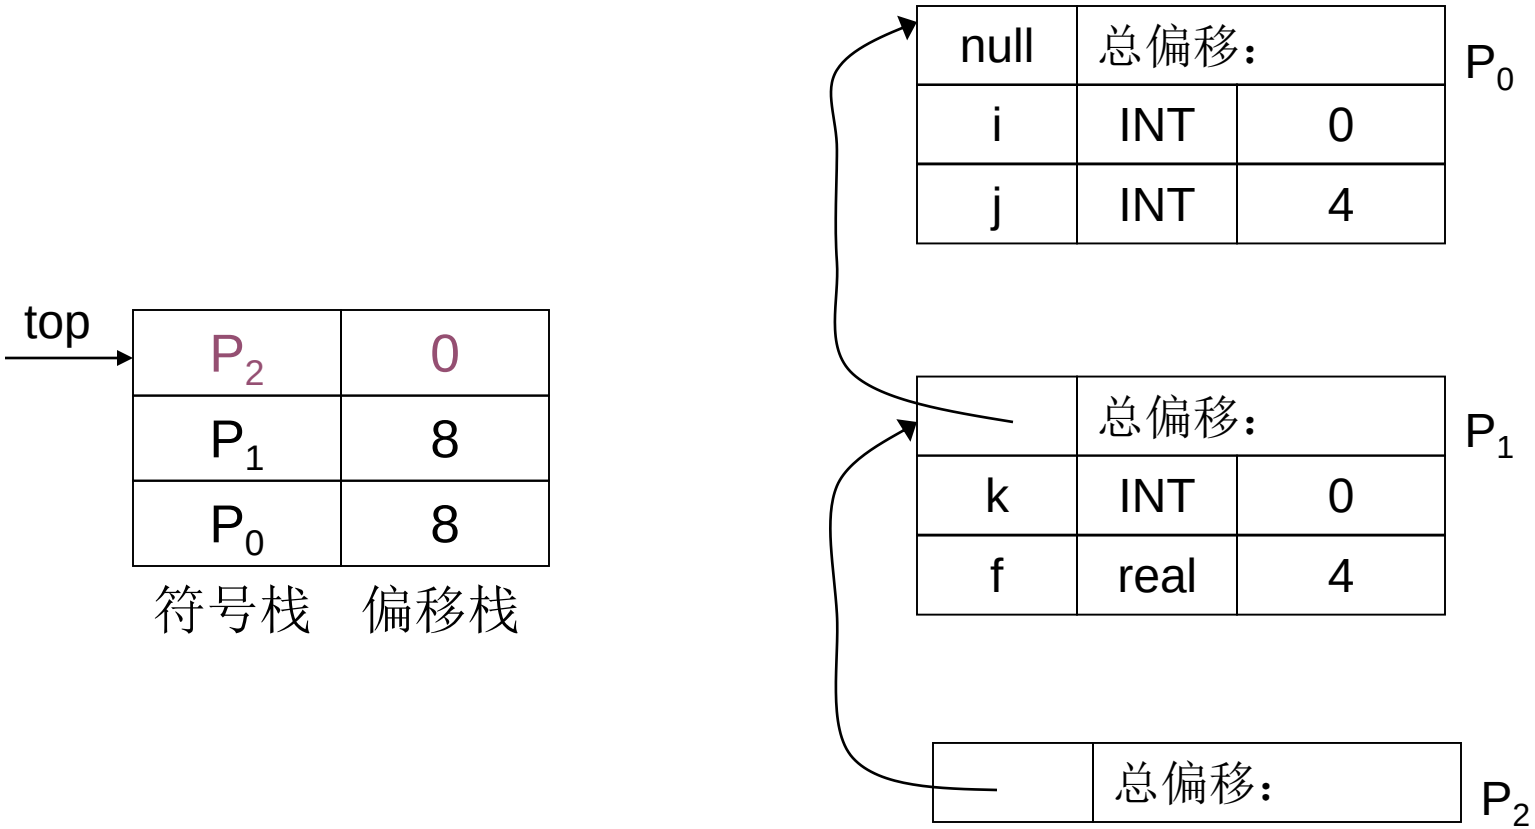

举例：过程嵌套声明

- l : int ;

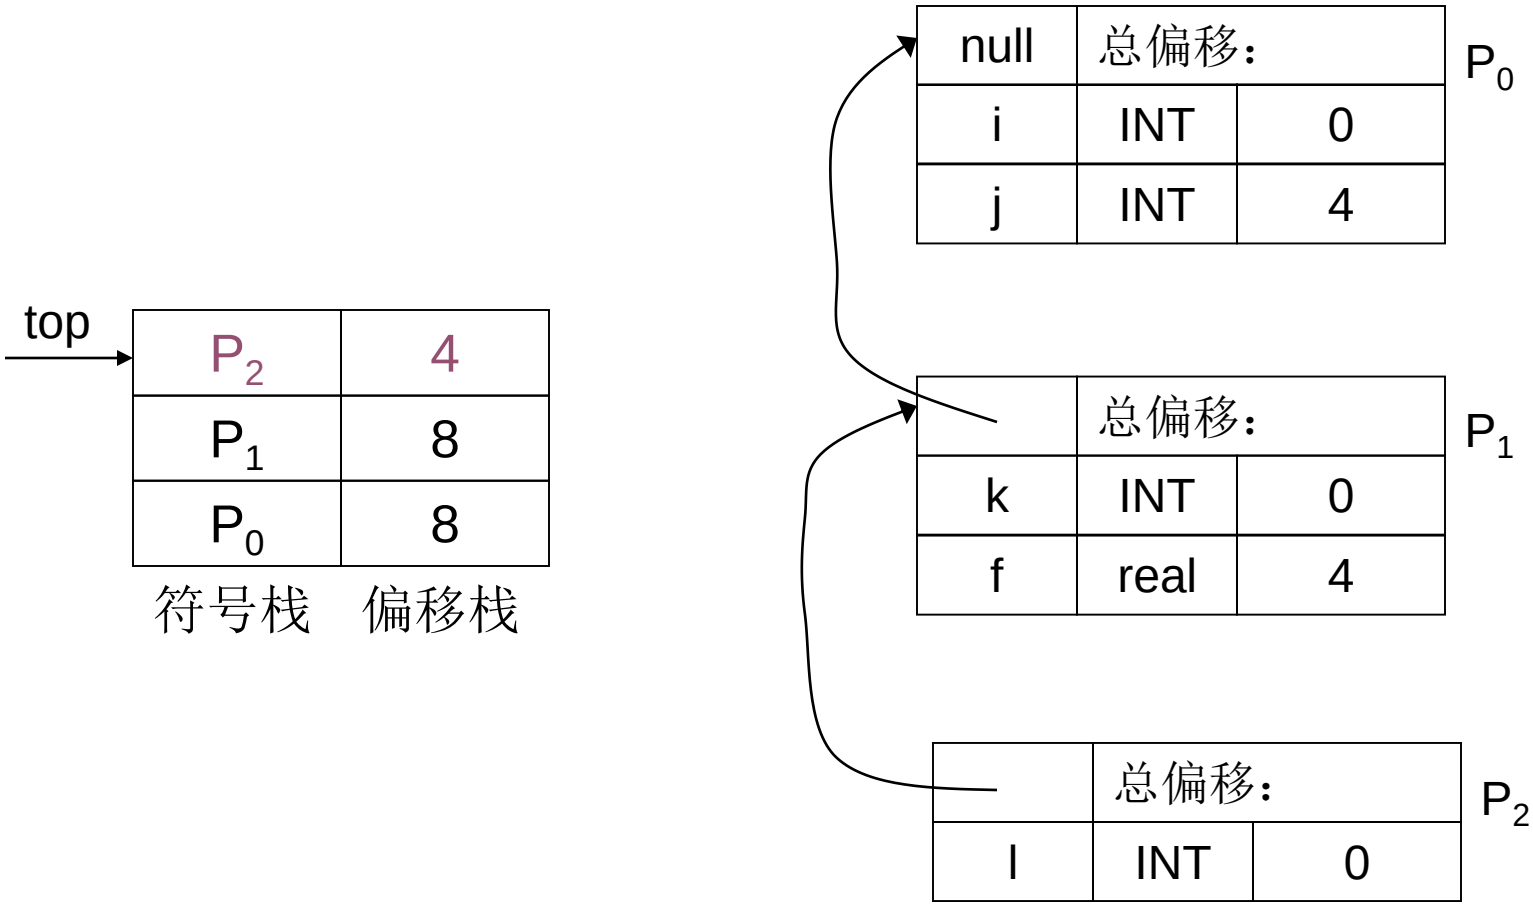

举例：过程嵌套声明

- a_1；

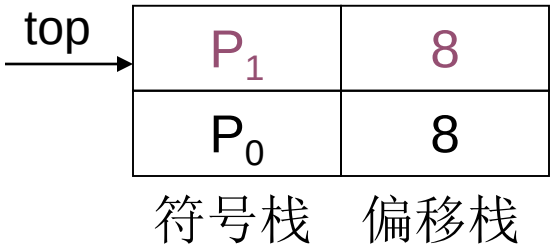
top
P1
8
P0
8
符号栈
偏移栈

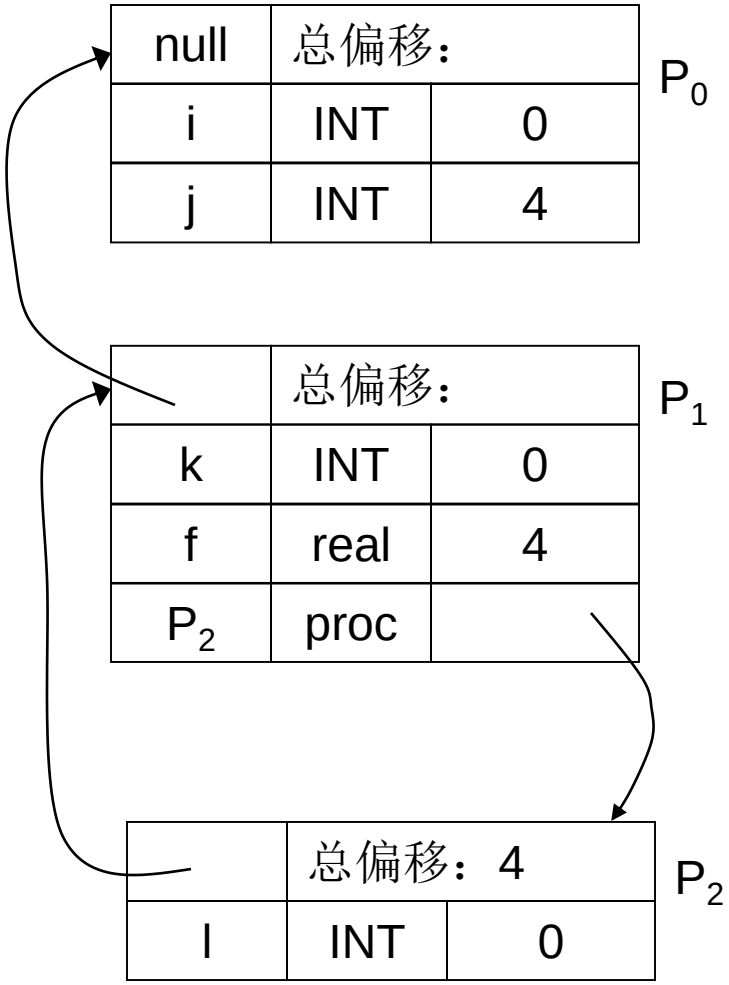
null
总偏移：
i
INT
0
j
INT
4
P0
总偏移：
k
INT
0
f
real
4
P2
proc
P1
总偏移：4
l
INT
0
P2

举例：过程嵌套声明

- a_2 ;

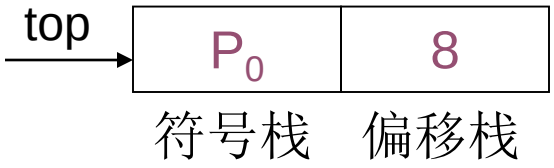
top
P0
8
符号栈
偏移栈

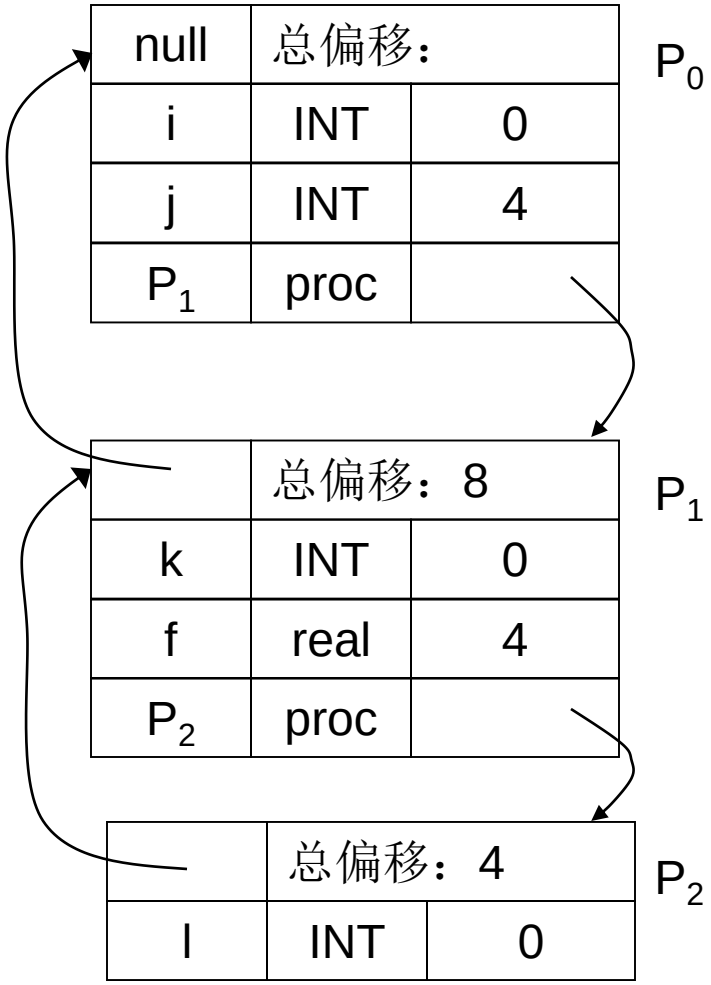
null
总偏移：
i
INT
0
j
INT
4
P1
proc
P0
总偏移：8
k
INT
0
f
real
4
P2
proc
P1
总偏移：4
l
INT
0
P2

举例：过程嵌套声明

- PROC P_3；（N→ε）

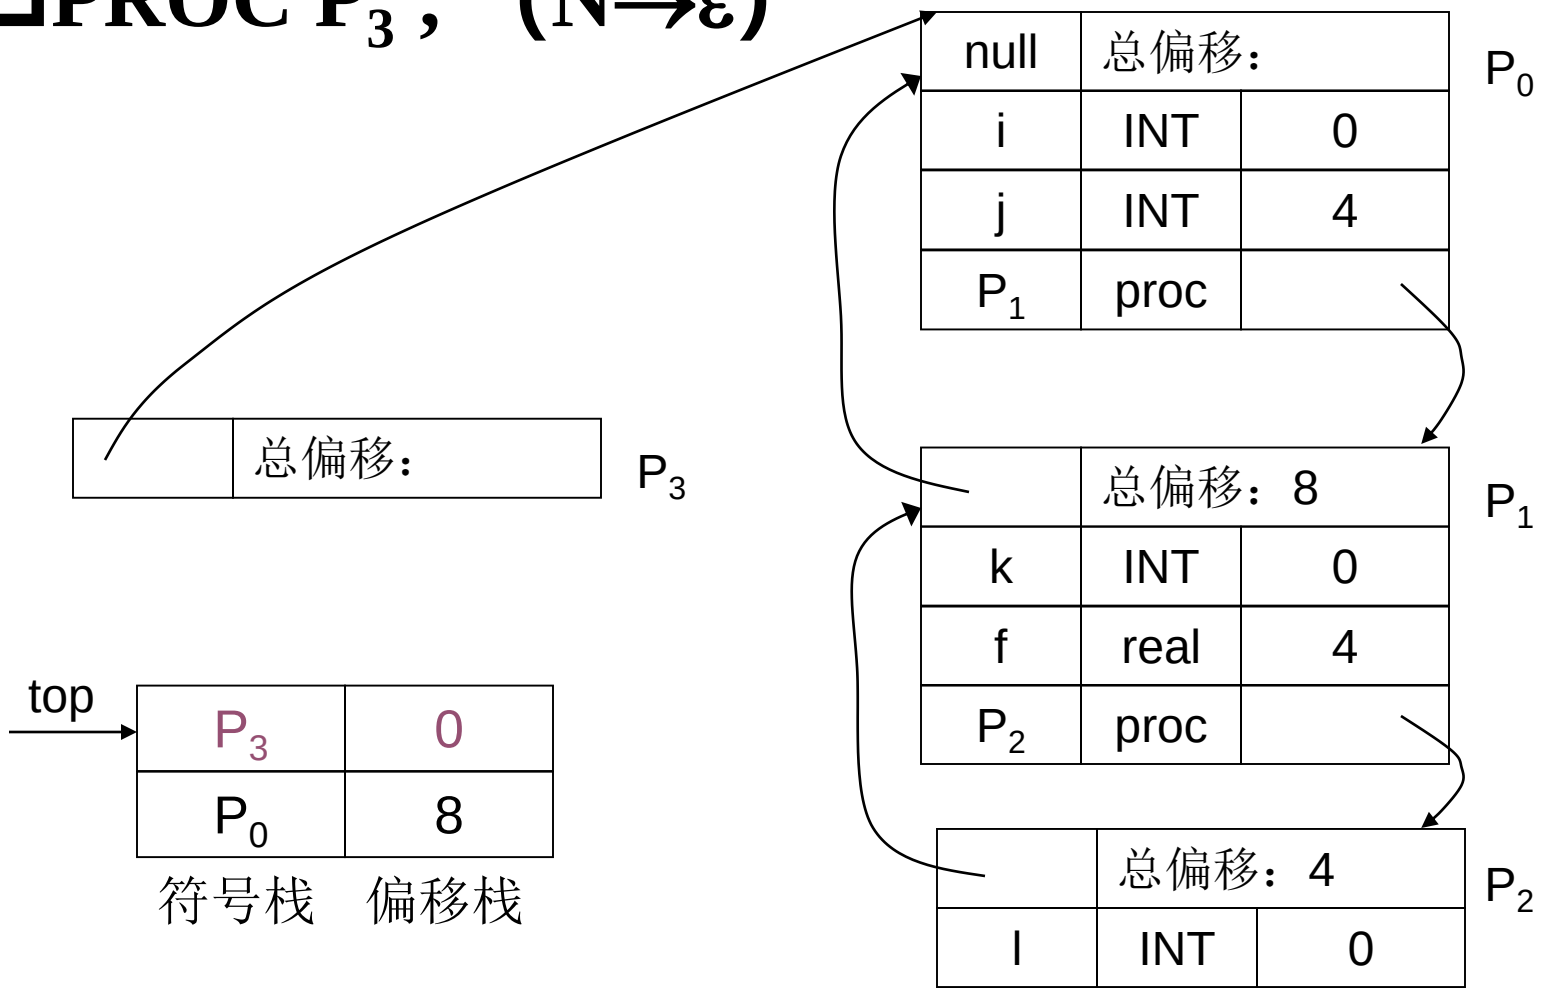

举例：过程嵌套声明

- temp : int; max : int;

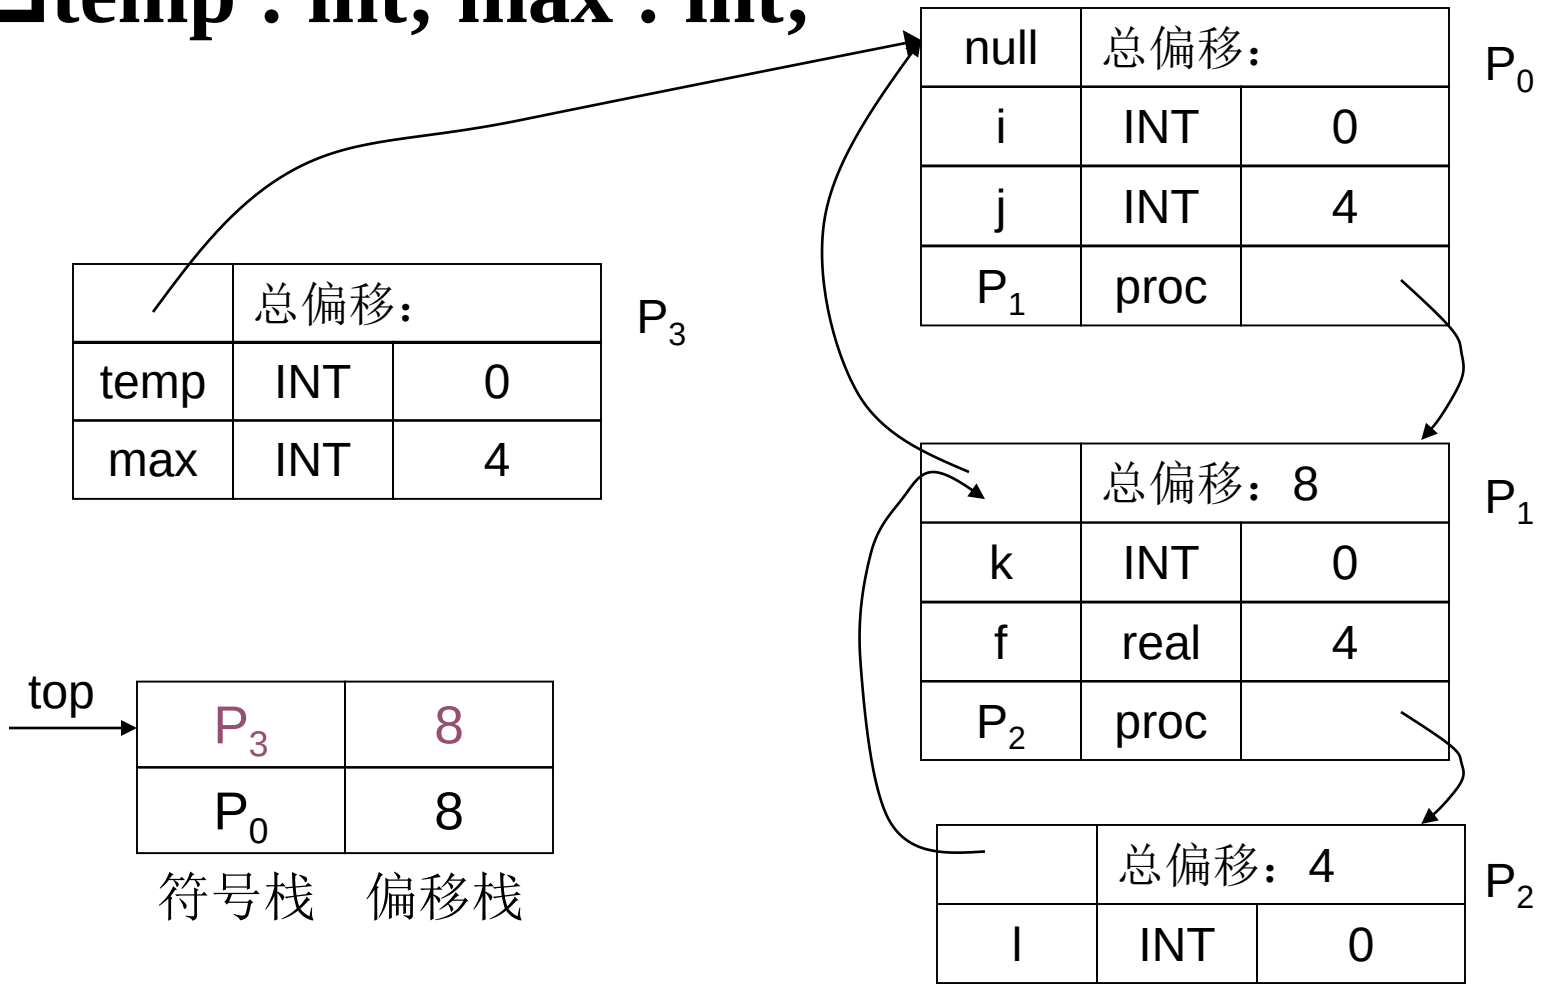

举例：过程嵌套声明

- a_3;

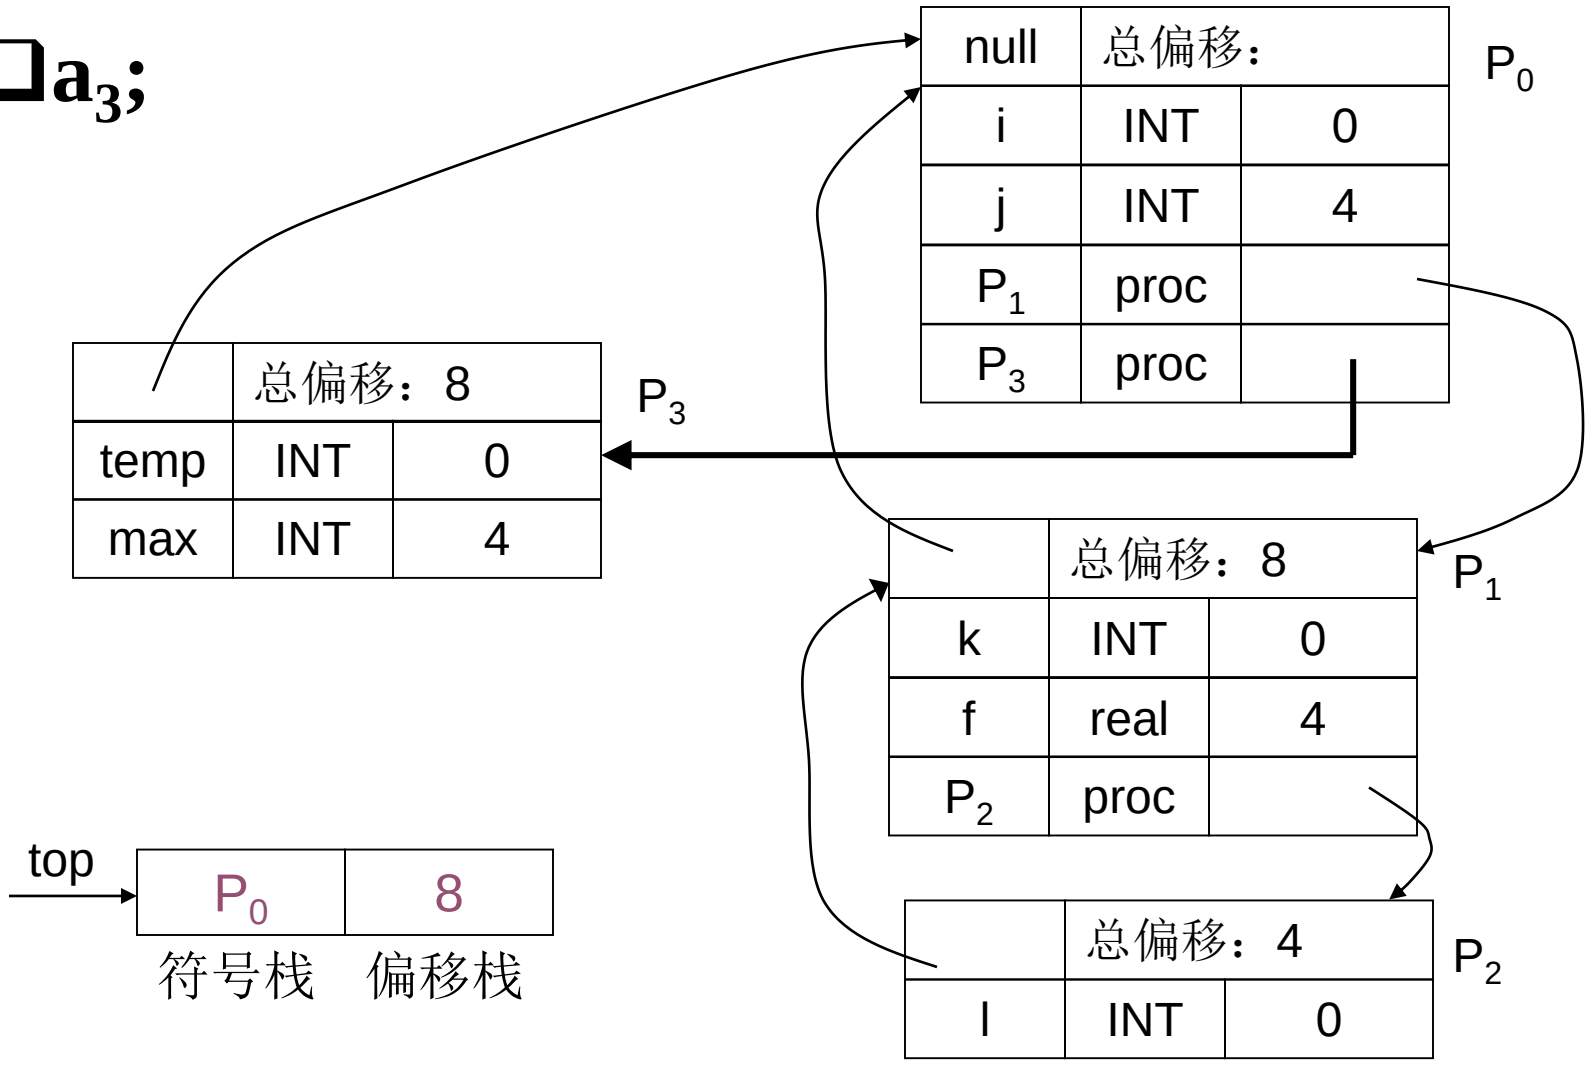
null
总偏移：
i
INT
0
j
INT
4
P1
proc
P3
proc
P0
总偏移：8
temp
INT
0
max
INT
4
P3
总偏移：8
k
INT
0
f
real
4
P2
proc
P1
总偏移：4
l
INT
0
P2
top
P0
8
符号栈
偏移栈

举例：过程嵌套声明

❑P→ M *D* ;

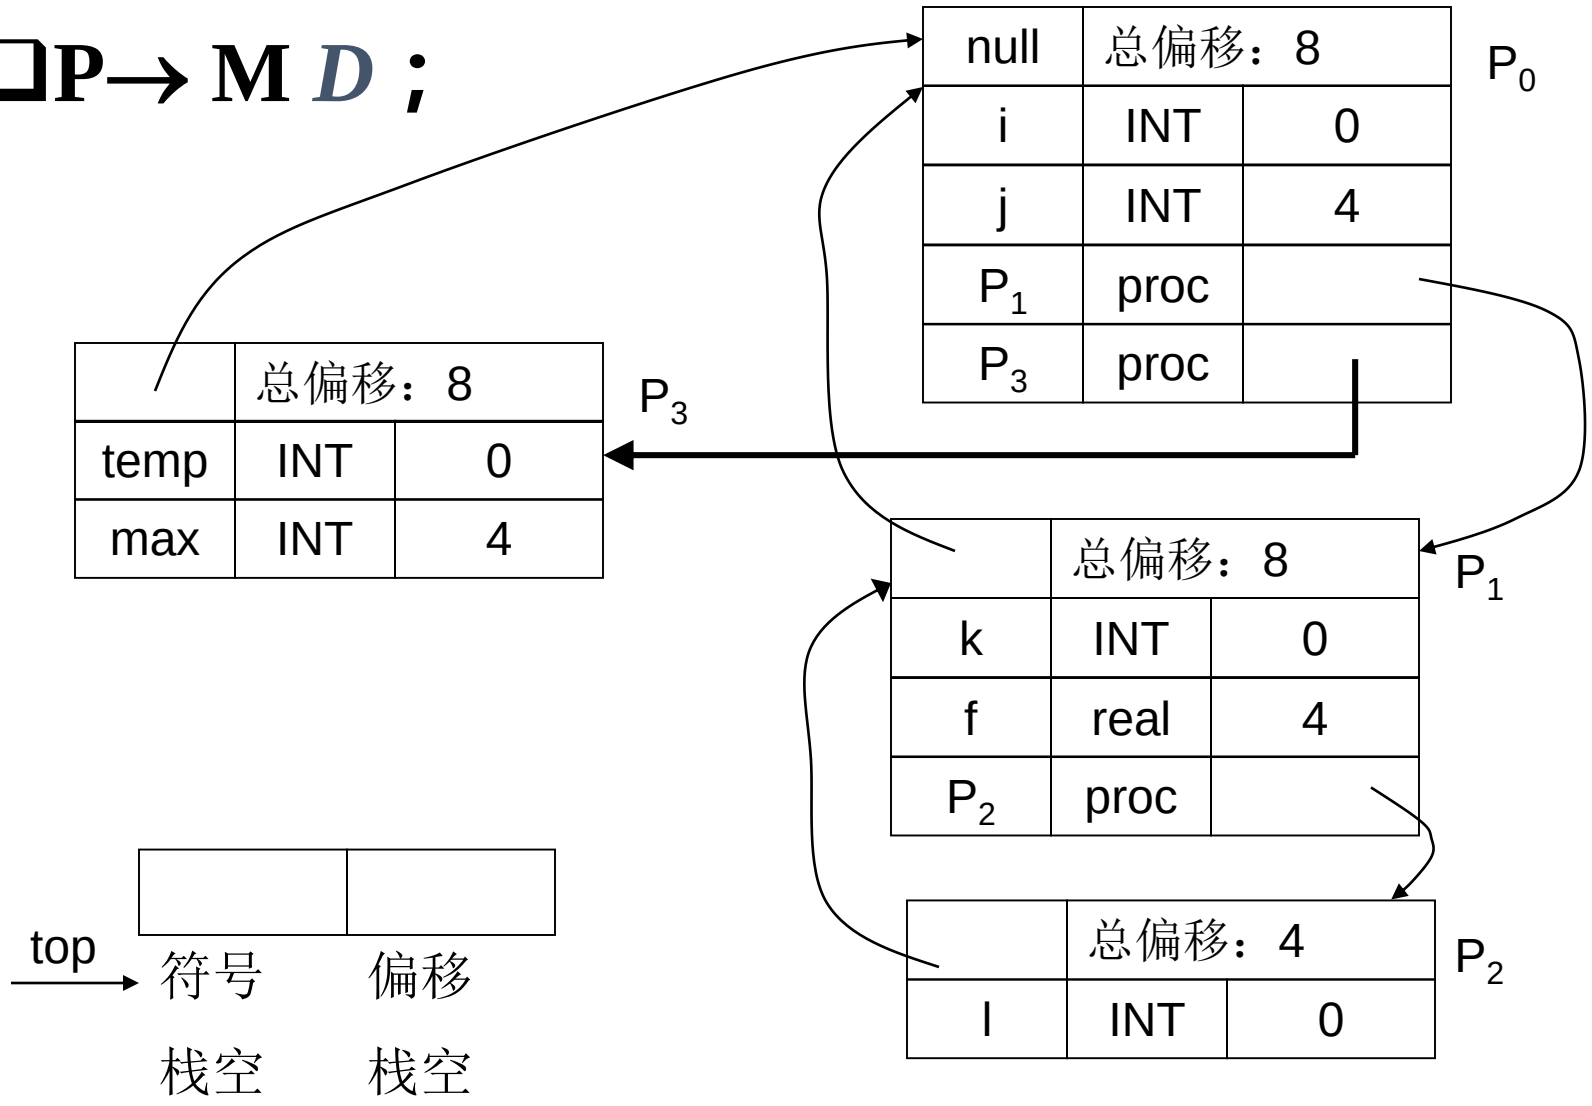

记录的域名管理

❑描述记录的文法

$T \rightarrow$ record D end

记录类型单独建符号表，域的相对地址从0开始

$T \rightarrow$ record L D end

$L \rightarrow \varepsilon$

```
record
    a :…;
    r : record
            i :…;
            . . .
        end;
     k : …;
end
```

记录的域名管理

❑描述记录的文法

$T \rightarrow$ record D end

记录类型单独建符号表，域的相对地址从0开始

$T \rightarrow$ record L D end

```
record
    a :…;
    r : record
            i :…;
            . . .
        end;
    k : …;
end
```

$L \rightarrow \varepsilon$ *t = mkTable(nil);*

push(t, tblptr); push(0, offset) }

建立符号表，进入作用域

记录的域名管理

❑描述记录的文法

$T \rightarrow$ record D end

记录类型单独建符号表，域的相对地址从0开始

$T \rightarrow$ record L D end

{*T.type = record (top(tblptr));*

T.width = top(offset);

pop(tblptr); pop(offset) }

$L \rightarrow \varepsilon$ *t = mkTable(nil);*

push(t, tblptr); push(0, offset) }

```
record
    a :…;
    r : record
            i :…;
            . . .
        end;
    k : …;
end
```

设置记录的类型表达式和宽度，退出作用域

记录的域名管理

❑描述记录的文法

$T \rightarrow$ record D end

记录类型单独建符号表，域的相对地址从0开始

$T \rightarrow$ record L D end

{*T.type = record (top(tblptr));*

T.width = top(offset);

pop(tblptr); pop(offset) }

$L \rightarrow \varepsilon$ *t = mkTable(nil);*

push(t, tblptr); push(0, offset) }

D的翻译同前

```
record
    a :…;
    r : record
            i :…;
            . . .
        end;
     k : …;
end
```

举例：记录域的偏移

- 有2个C语言的结构定义如下：

```
struct A {
    char c1;
    char c2;
    long l;
    double d;
} S1;
```

```
struct B {
    char c1;
    long l;
    char c2;
    double d;
} S2;
```

举例：记录域的偏移

- 数据（类型）的对齐 - alignment
- 在 X86-Linux下：
  - char：对齐1，起始地址可分配在任意地址
  - int，long，double：对齐4，即从被4整除的地址开始分配
- 注*：其它类型机器，double可能对齐到8
  - 如sun－SPARC

举例：记录域的偏移

- 结构A 和 B的大小分别为16和20字节(Linux)

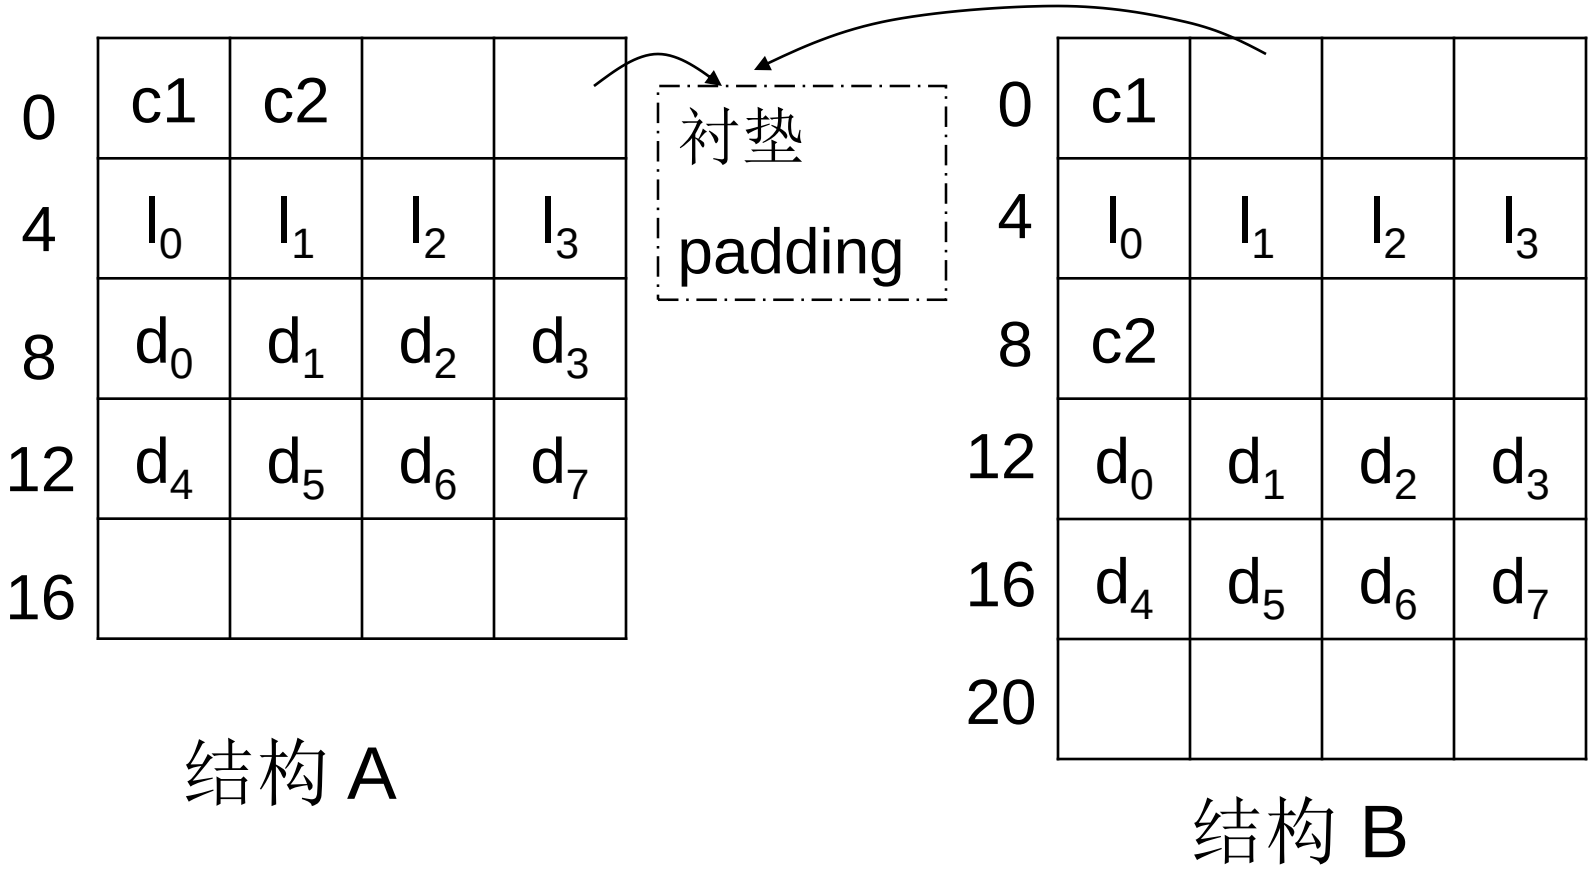

举例：记录域的偏移

❑2个结构中域变量的偏移如下：

```
struct A {
  char c1;
  char c2;
  long l;
  double d;
} S1;
```

```
struct B {
    char c1;
    long l;
    char c2;
    double d;
} S2;
```

举例：记录域的偏移

❑2个结构中域变量的偏移如下：

```
struct A {
  char c1;   0
  char c2;   1
  long l;    4
  double d;  8
} S1;
```

```
struct B {
    char c1;    0
    long l;     4
    char c2;    8
    double d;  12
} S2;
```

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》
中间代码生成 I

Computer Science is a science of abstraction - creating the right model for a problem and devising the appropriate mechanizable techniques to solve it.

——A. Aho and J. Ullman