



软件分析

# 数据流分析：基础

熊英飞  
北京大学

2018



# 复习

- 大多数程序分析问题都是不可判定问题
  - 莱斯定理
- 解决途径是对程序做抽象
  - must分析/下近似
  - may分析/上近似



# 复习 – 停机问题的证明方法

- 假设存在停机问题判断算法:  $\text{bool Halt}(p)$ 
  - $p$ 为特定程序
- 给定某邪恶程序

```
void Evil() {  
    if (!Halt(Evil)) return;  
    else while(1);  
}
```
- $\text{Halt}(\text{Evil})$ 的返回值是什么?
  - 如果为真, 则Evil不停机, 矛盾
  - 如果为假, 则Evil停机, 矛盾



# 停机问题-抽象方法

- 邪恶程序存在的关键在于程序中有if存在
- 不如忽略掉所有程序的if条件部分

```
void Evil() {  
    if (!Halt(Evil)) return;  
    else while(1);  
}
```



```
void Evil() {  
    向左走 return;  
    向右走 while(1);  
}
```

- 语义：“向左走/向右走”为非确定性选择，程序随机从“向左走”和“向右走”后面的语句中选择一条执行。



# 停机问题-抽象方法

- 邪恶程序仍然可以用循环写出

```
void Evil() {  
    while (Halt(Evil));  
}
```

- 忽略所有条件判断中的条件，一律抽象为不确定选择

```
void Evil() {  
   再来一次:  
    向左走 goto 再来一次;  
    向右走 return;  
}
```



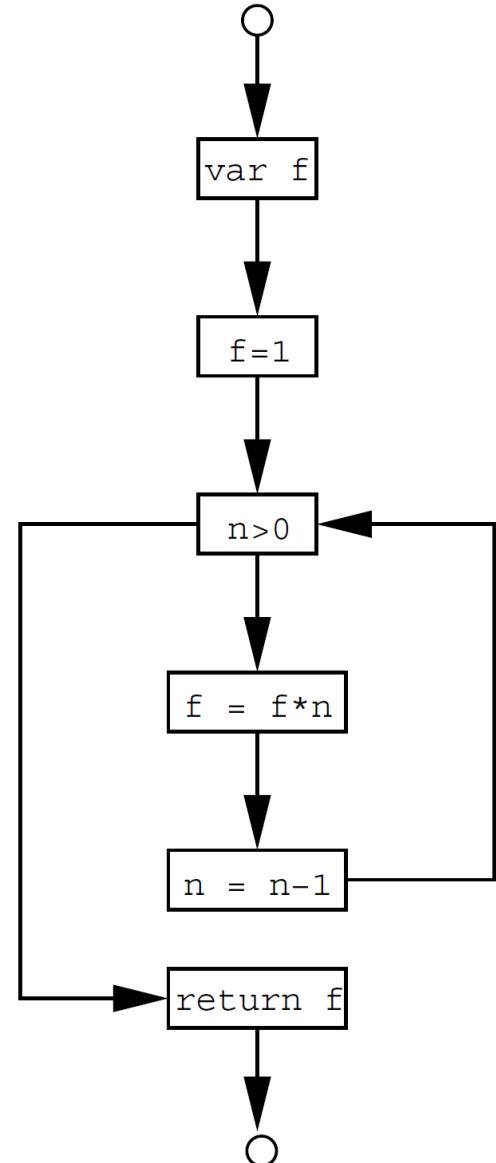
# 停机问题-抽象过程分析

- 针对给定输入
  - 原始程序只有一条执行路径， 抽象程序上有多条执行路径
  - 原始程序的执行路径一定包含在抽象程序的执行路径中
- 停机问题
  - 原始程序停机： 存在自然数 $n$ ， 程序的执行路径长度小于 $n$
  - 抽象程序停机： 存在自然数 $n$ ， 程序中所有执行路径的长度都小于 $n$



# 停机问题-判定方法

- 判断方法：绘制控制流图
  - 控制流图：结点为程序语句，边头语句间的转移
- 如果控制流图上有环，则可能不终止，否则一定终止





# 数据流分析-小结1

- 近似方案1：忽略掉程序的条件判断，认为所有分支都有可能到达
- 数据流分析：程序可以看成是状态（数据）和状态之间的转移（控制）两部分，因为状态转移的条件都被忽略了，核心分析的部分是状态数据在转移过程中的变化，所以叫做数据流分析。



# 符号分析

- 给定一个只包含浮点数变量和常量的程序，已知输入的符号，求输出的符号
- 采用上节课讲到的抽象域，输出正、零、负、裸四种结果



# 复习：符号分析的抽象

- 抽象符号
  - 正 = {所有的正数}
  - 零 = {0}
  - 负 = {所有的负数}
  - 𩶻 = {所有的整数和NaN}
- 运算 (列标号 ● 行标号)

+	正	负	零	𩶻
正	正			
负	𩶻	负		
零	正	负	零	
𩶻	𩶻	𩶻	𩶻	𩶻



-	正	负	零	踩
正	踩	负	负	踩
负	正	踩	正	踩
零	正	负	零	踩
踩	踩	踩	踩	踩

*	正	负	零	踩
正	正			
负	负	正		
零	零	零	零	
踩	踩	踩	踩	踩

/	正	负	零	踩
正	正	负	零	踩
负	负	正	零	踩
零	踩	踩	踩	踩
踩	踩	踩	踩	踩



# 符号分析-示例

```
x*=-100;
```

```
y+=1;
```

```
while(y < z) {
```

```
    x *= -100;
```

```
    y += 1;
```

```
}
```

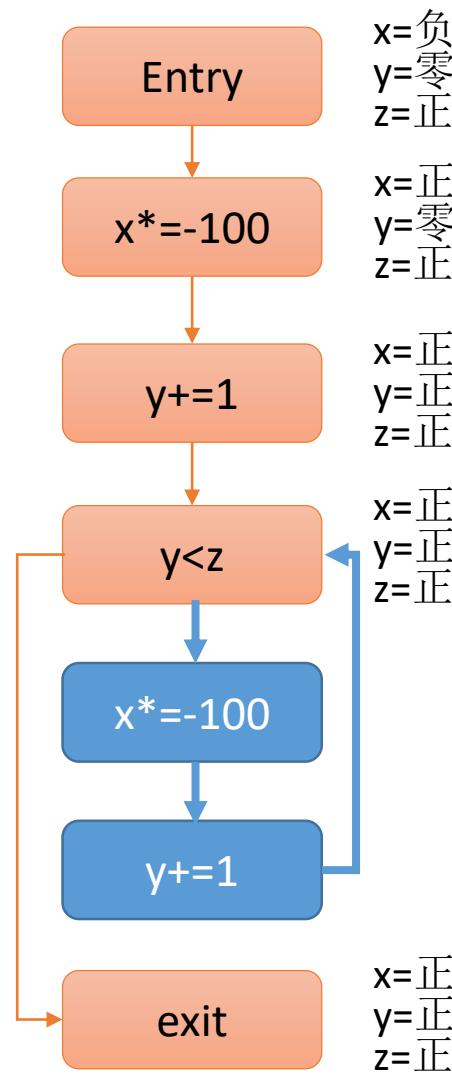
输入： x为负， y为零， z为正

输出： x为偶数， y为正， z为正



# 符号分析-基本思路

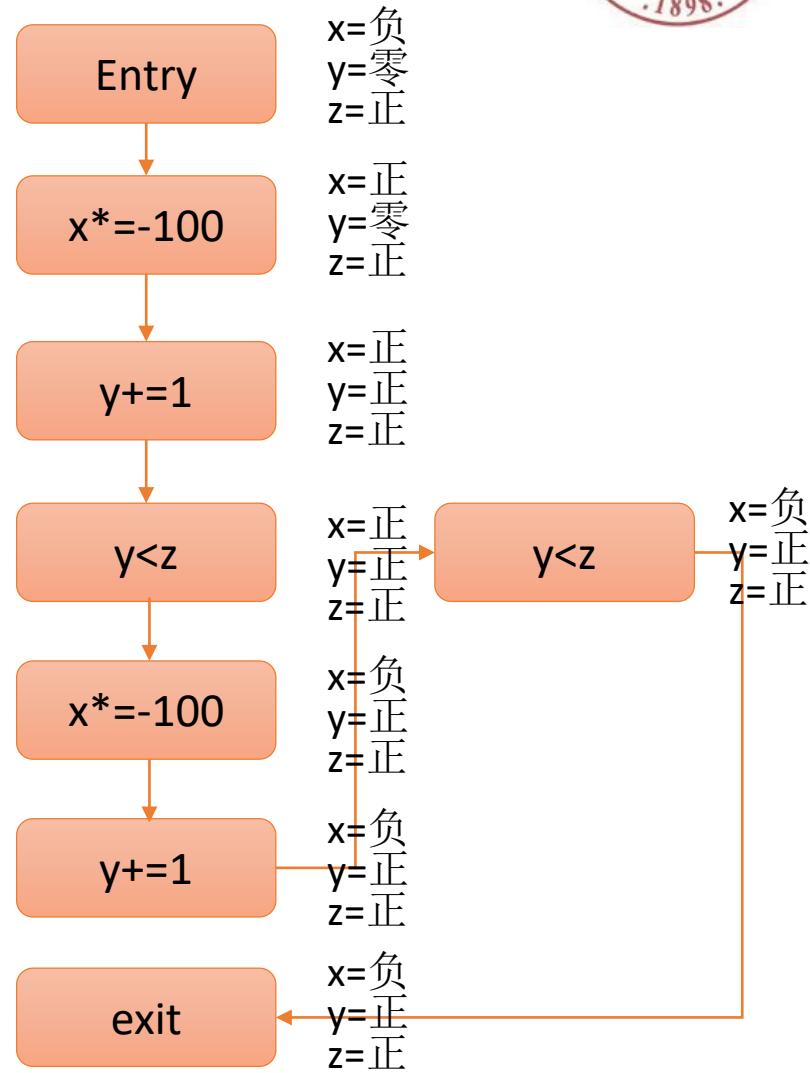
- 给定程序的一条执行路径，我们能推出结果符号的抽象取值





# 符号分析-基本思路

- 给定程序的两条执行路径，我们得到两个结果符号的抽象取值  $v_1, v_2$ ，我们可以用如下的操作来合并这两个值：
  - $\sqcap(v_1, v_2) = \begin{cases} v_1 & \text{如果 } v_1 = v_2 \\ \text{踩} & \text{其他情况} \end{cases}$
- $\sqcap((\text{正正正}), (\text{负正正})) = (\text{踩正正})$





# 符号分析-基本思路

- 如果我们能知道程序所有可能的路径产生的结果符号 $v_1, v_2, \dots$ , 我们就知道了程序的最终结果口 $(v_1, v_2, \dots)$ 。
- 如何知道程序有哪些可能的路径?
  - 近似方案1: 忽略掉程序的条件判断, 认为所有分支都有可能到达
- 如何能遍历所有可能的路径?
  - 近似方案2: 不在路径末尾做合并, 在控制流汇合的所有位置提前做合并

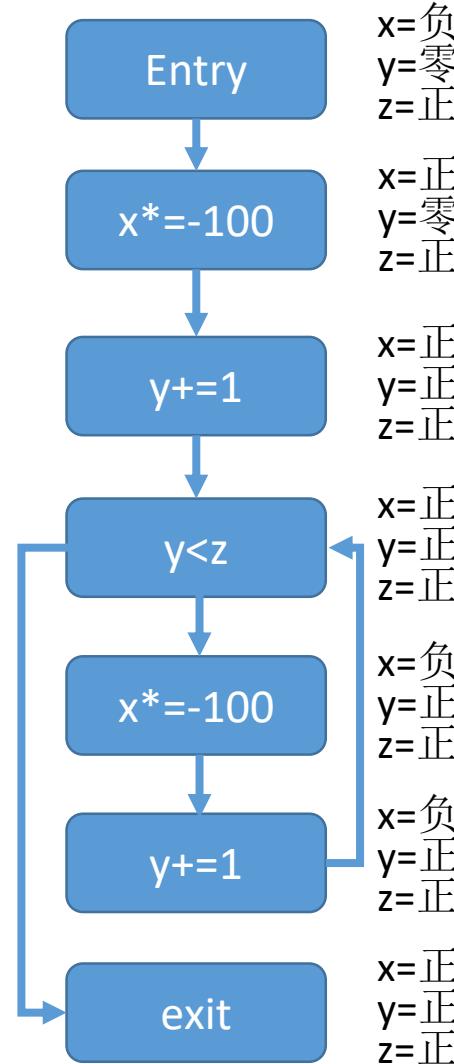


# 符号分析-示例

```
x*=-100;
```

```
y+=1;
```

```
while(y < z) {  
    x *= -100;  
    y += 1;  
}
```



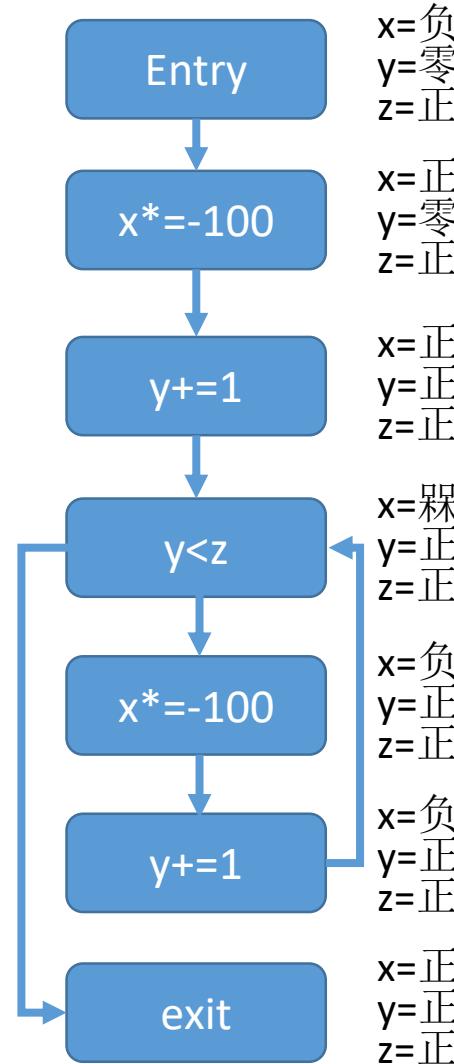


# 符号分析-示例

```
x*=-100;
```

```
y+=1;
```

```
while(y < z) {  
    x *= -100;  
    y += 1;  
}
```



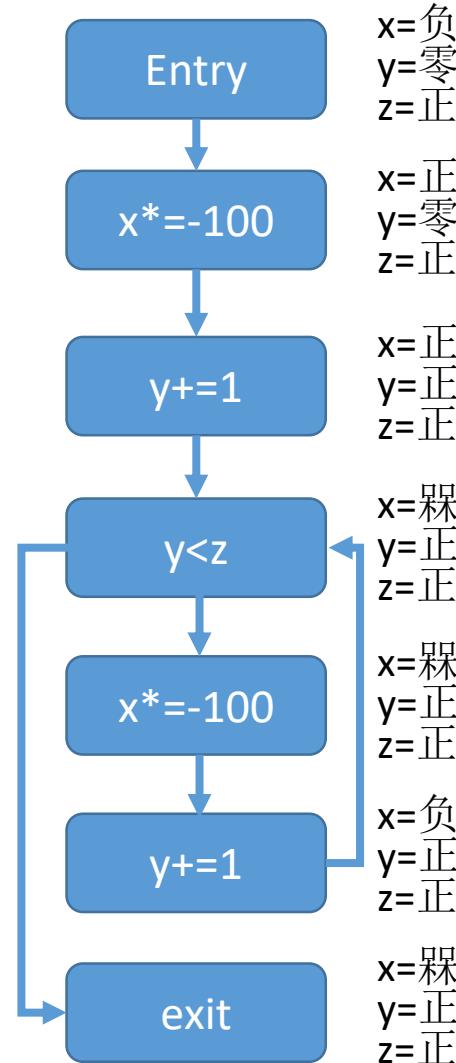


# 符号分析-示例

```
x*=-100;
```

```
y+=1;
```

```
while(y < z) {  
    x *= -100;  
    y += 1;  
}
```



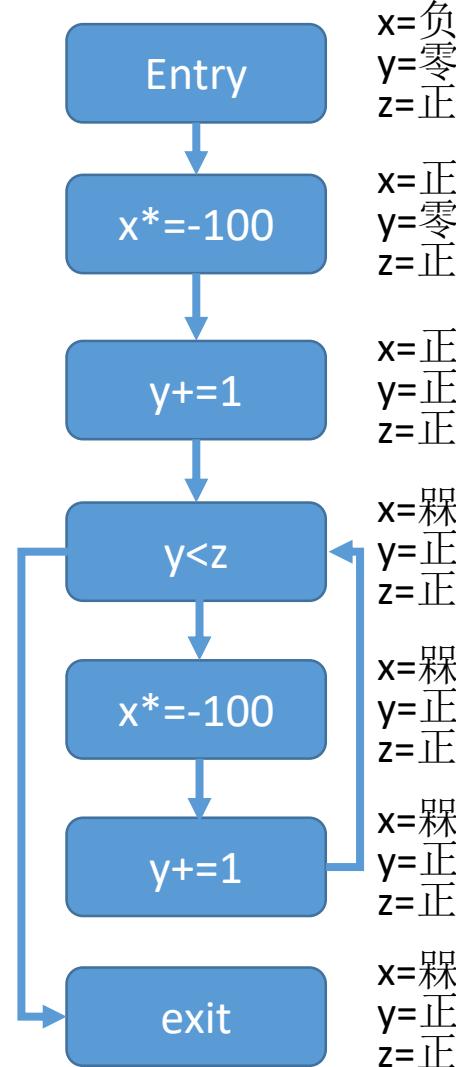


# 符号分析-示例

```
x*=-100;
```

```
y+=1;
```

```
while(y < z) {  
    x *= -100;  
    y += 1;  
}
```





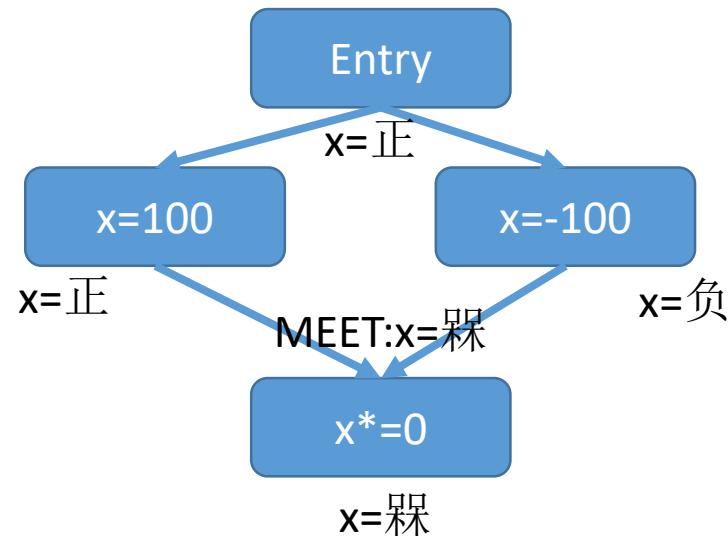
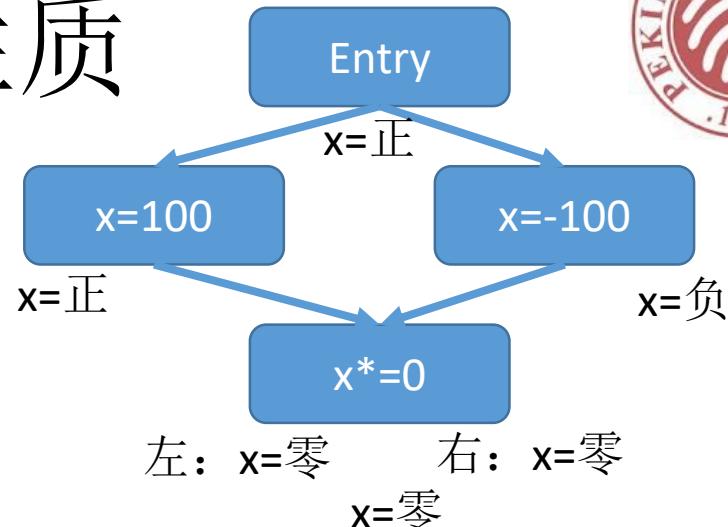
# 符号分析-算法

- 令  $\mathbf{S} = \{(s_x, s_y, s_z) | s_x, s_y, s_z \in \{\text{正, 负, 零, 保, T}\}\}$
- 每个结点的值为  $\mathbf{S}$  的一个元素，代表对应语句执行之后的变量符号，用 DATA 表示
- 初始值
  - $\text{DATA}_{entry} = (\text{负}, \text{零}, \text{正})$
  - $\text{DATA}_{\text{其他结点}} = (T, T, T)$
- 结点转换函数  $f_v: \mathbf{S} \rightarrow \mathbf{S}$ 
  - $f_{exit} = id$
  - $f_{\text{其他结点}} = \text{根据相应语句进行计算}$
- 交汇运算  $MEET_v = \sqcap_{w \in pred(v)} \text{DATA}_w$ ,  $\sqcap$  操作扩展到 T:  $x \sqcap T = x$
- 结点更新运算  $S_v = f_v(MEET_v)$
- 如果某个结点的前驱结点发生了变化，则使用结点更新运算更新该结点的附加值
- 如果没有任何结点的值发生变化，则程序终止。



# 符号分析-算法性质

- 该算法是安全的吗?
  - 近似方案2并非等价变换，那么该近似方案是安全的吗?
- 该算法保证终止(Terminating)吗?
  - 路径上有环的时候，是否会一直循环?
- 该算法一定合流(Confluent)吗?
  - 有多个结点可更新的时候，是否无论先更新哪个结点最后都会到达同样的结果?
- 终止+合流=收敛(Convergence)
- 以上问题的答案将在数据流分析框架部分统一回答





# 数据流分析-小结2

- 给出一条程序路径上的分析方案，和不同路径上的结果合并方案
- 近似方案1：忽略掉程序的条件判断，认为所有分支都有可能到达
- 近似方案2：不在路径末尾做合并，在控制流汇合的所有位置提前做合并

# 数据流分析-活跃变量分析 (Liveness Analysis)

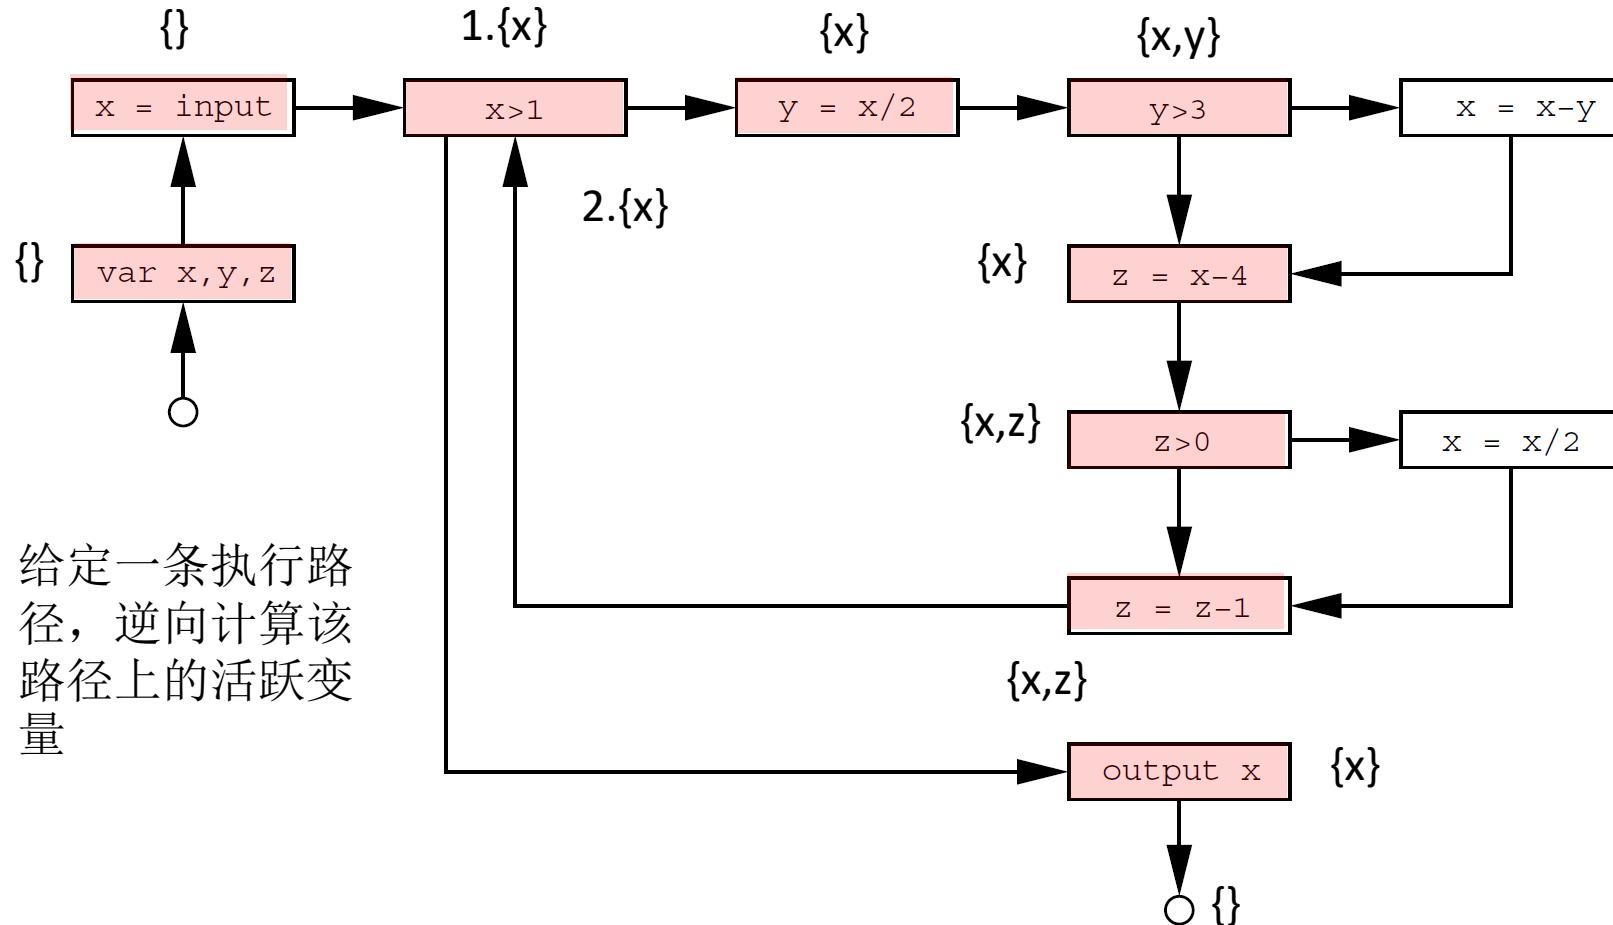


- 活跃变量：给定程序中的某条语句 $s$ 和变量 $v$ ，如果在 $s$ 执行前保存在 $v$ 中的值在后续执行中还会被读取就被称作活跃变量
- 第四行的 $y$ 和 $x$ 是否为活跃变量？
- 第八行的 $y$ 和 $z$ 呢？
- 活跃变量分析：返回所有可能的活跃变量
  - may分析

1. var x,y,z;
2. x = input;
3. while (x>1) {
4.     y = x/2;
5.     if (y>3) x = x-y;
6.     z = x-4;
7.     if (z>0) x = x/2;
8.     z = z-1;
9. }
10. output x;

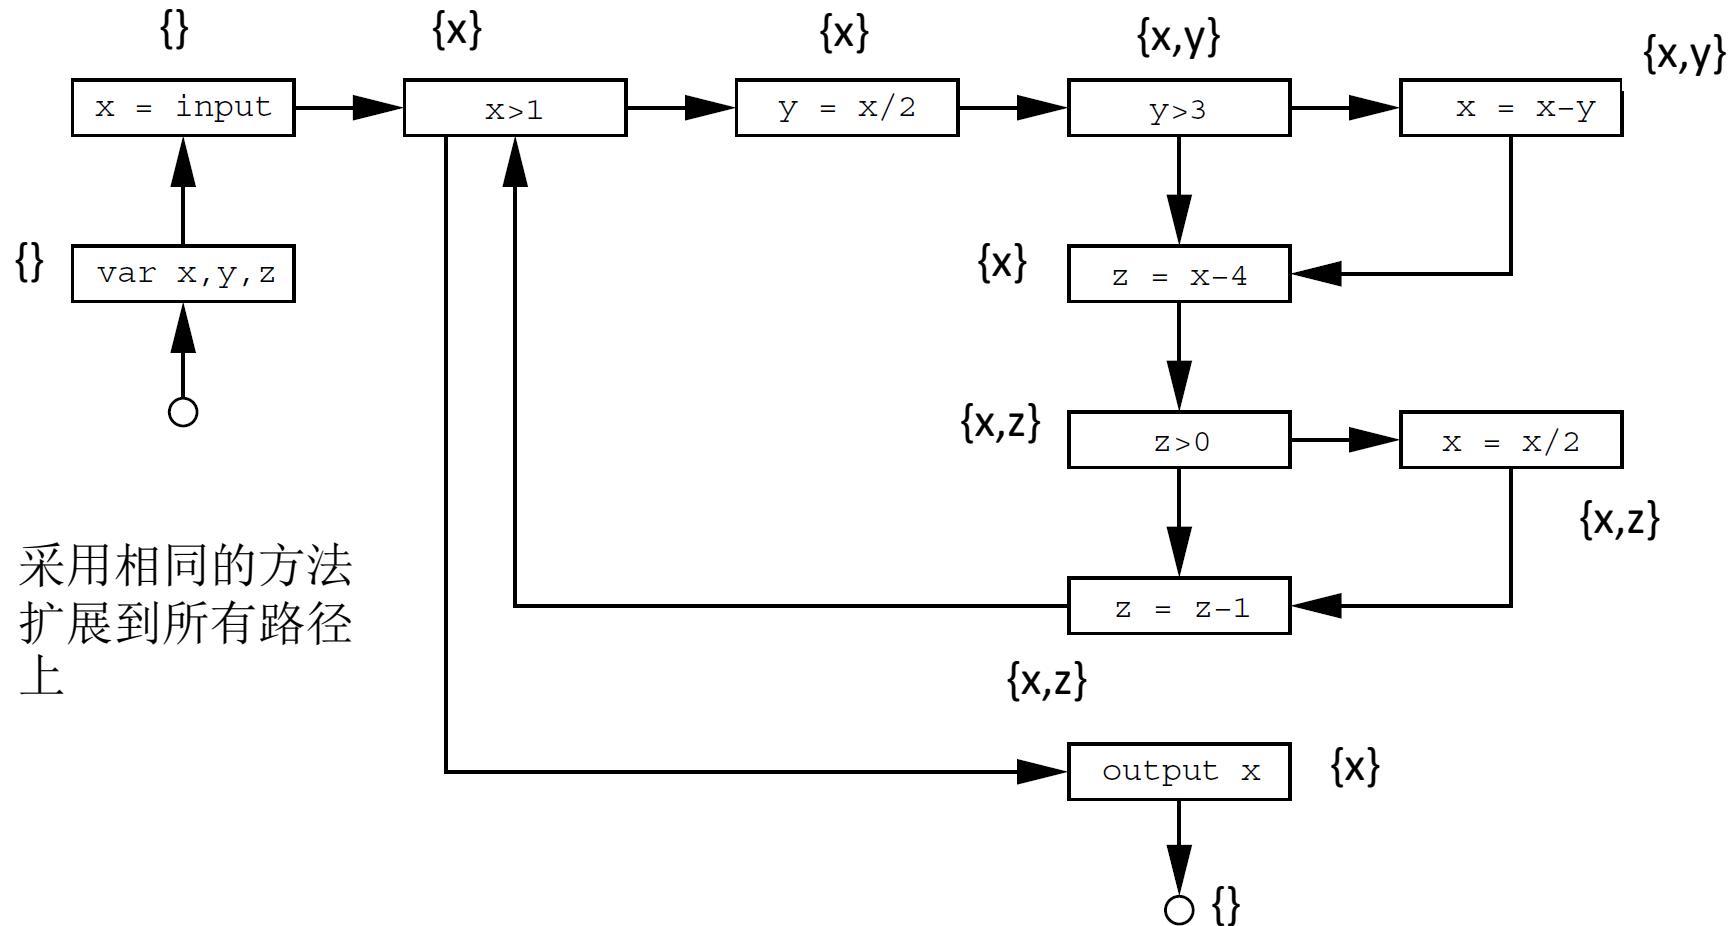


# 活跃变量分析-基本思想





# 活跃变量分析-例子





# 活跃变量分析-算法

- 初始值:  $DATA_V = \{\}$
- 结点转换函数:  $f_v(L) = (L \setminus KILL_v) \cup GEN_v$ 
  - $GEN_v = vars(v)$
  - $KILL_v = \begin{cases} \{x\} & v := x = \text{exp}; \\ \{x\} & v := \text{int } x; \\ \{\} & otherwise \end{cases}$
- 交汇运算  $MEET_V = \bigcup_{w \in succ(v)} DATA_w$
- 结点更新运算  $L_v = f_v(MEET_v)$
- 如果某个结点的后继结点发生了变化，则使用结点更新运算更新该结点的附加值
- 如果没有任何结点的值发生变化，则程序终止。



# 活跃变量分析-算法性质

- 该算法是安全的吗?
  - 安全性: 每个节点对应的L集合包括了所有的活跃变量
  - 对于单条路径, 该性质可以归纳证明
  - 如何证明对所有路径的安全性?
- 该算法保证收敛吗?



# 数据流分析单调框架

- 数据流分析单调框架：对前面所述算法以及所有同类算法的一个通用框架
- 目标：通过配置框架的参数，可以导出各种类型的算法，并保证算法的安全性、终止性、收敛性
- 需要抽象的内容
  - 不同算法在结点上附加的值的类型不同，需要有一个统一接口
  - 不同算法给出的结点转换函数不同，需要有一个统一接口



# 半格 (semilattice)

- 半格是一个二元组 $(S, \sqcap)$ , 其中 $S$ 是一个集合,  $\sqcap$ 是一个交汇运算, 并且任意 $x, y, z \in S$ 都满足下列条件:
  - 幂等性idempotence:  $x \sqcap x = x$
  - 交换性commutativity:  $x \sqcap y = y \sqcap x$
  - 结合性associativity:  $(x \sqcap y) \sqcap z = x \sqcap (y \sqcap z)$
  - 存在一个最大元 $\top$ , 使得 $x \sqcap \top = x$



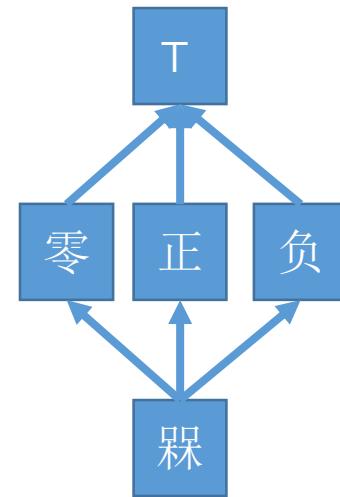
# 偏序 Partial Order

- 偏序是一个二元组 $(S, \sqsubseteq)$ , 其中 $S$ 是一个集合,  $\sqsubseteq$ 是一个定义在 $S$ 上的二元关系, 并且满足如下性质:
  - 自反性:  $\forall a \in S: a \sqsubseteq a$
  - 传递性:  $\forall x, y, z \in S: x \sqsubseteq y \wedge y \sqsubseteq z \Rightarrow x \sqsubseteq z$
  - 非对称性:  $x \sqsubseteq y \wedge y \sqsubseteq x \Rightarrow x = y$
- 每个半格都定义了一个偏序关系
  - $x \sqsubseteq y$ 当且仅当 $x \sqcap y = x$



# 半格示例

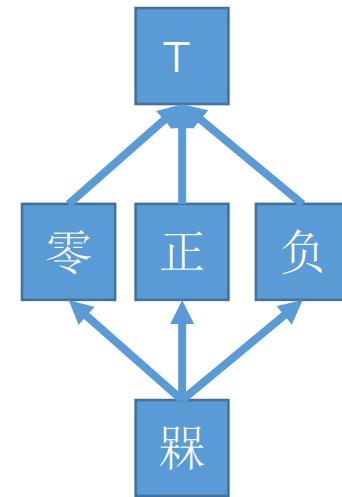
- 抽象符号域的五个元素和交汇操作组成了一个半格
- 半格的笛卡尔乘积( $S \times T, \sqcap_{xy}$ )还是半格
  - $(s_1, t_1) \sqcap_{xy} (s_2, t_2) = (s_1 \sqcap_x s_2, t_1 \sqcap_y t_2)$
- 任意集合和交集操作组成了一个半格
  - 偏序关系为子集关系
  - 顶元素为全集
- 任意集合和并集操作组成了一个半格
  - 偏序关系为超集关系
  - 顶元素为空集





# 半格的高度

- 半格的偏序图中任意两个结点的最大距离+1
- 示例：
  - 抽象符号域的半格高度为3
  - 集合和交集/并集组成的半格高度为集合大小+1
    - 活跃变量分析中半格高度为变量总数+1





# 集合的最大下界

- 下界：给定集合 $S$ ，如果满足 $\forall s \in S : u \sqsubseteq s$ ，则称 $u$ 是 $S$ 的一个下界
- 最大下界：设 $u$ 是集合 $S$ 的下界，给定任意下界 $u'$ ，如果满足 $u' \sqsubseteq u$ ，则称 $u$ 是 $S$ 的最大下界，记为 $\top_S$
- 引理： $\sqcap_{s \in S} s$ 是 $S$ 的最大下界
  - 证明：
    - 根据幂等性、交换性和结合性，我们有 $\forall v \in S : (\sqcap_{s \in S} s) \sqcap v = \sqcap_{s \in S} s$ ，所以 $\sqcap_{s \in S} s$ 是 $S$ 的下界
    - 给定另一个下界 $u$ ，我们有 $\forall s \in S : s \sqcap u = u$ ， $(\sqcap_{s \in S} s) \sqcap u = (\sqcap_{s \in S} (s \sqcap u)) = u$ ，所以 $\sqcap_{s \in S} s$ 是最大下界
  - 推论：半格的任意子集都有最大下界



# 单调（递增）函数

## Monotone (Increasing) Function

- 给定一个偏序关系 $(S, \sqsubseteq)$ , 称一个定义在 $S$ 上的函数 $f$ 为单调函数, 当且仅当对任意 $a, b \in S$ 满足
  - $a \sqsubseteq b \Rightarrow f(a) \sqsubseteq f(b)$
  - 注意: 单调不等于 $a \sqsubseteq f(a)$
- 单调函数示例
  - 在符号分析的半格中, 固定任一输入参数, 抽象符号的四个操作均为单调函数
  - 在集合和交/并操作构成的半格中, 给定任意两个集合 $\text{GEN}, \text{KILL}$ , 函数 $f(S) = (S - \text{KILL}) \cup \text{GEN}$ 为单调函数



# 数据流分析单调框架

- 一个控制流图( $V, E$ )
- 一个有限高度的半格( $S, \sqcap$ )
- 一个entry的初值 $I$
- 一组结点转换函数，对任意 $v \in V - entry$ 存在一个结点转换函数 $f_v$
- 注意：对于逆向分析，变换控制流图方向再应用单调框架即可



# 数据流分析实现算法

$\text{DATA}_{\text{entry}} = I$

$\forall v \in (V - \text{entry}): \text{DATA}_v \leftarrow \top$

$\text{ToVisit} \leftarrow V - \text{entry}$  //可以换成 $\text{succ}(\text{entry})$ 吗?

While( $\text{ToVisit.size} > 0$ ) {

$v \leftarrow \text{ToVisit}$ 中任意结点

ToVisit -= v

$\text{MEET}_v \leftarrow \sqcap_{w \in \text{pred}(v)} \text{DATA}_w$

If( $\text{DATA}_V \neq f_v(\text{MEET}_v)$ ) ToVisit  $\cup= \text{succ}(v)$

$\text{DATA}_v \leftarrow f_v(\text{MEET}_v)$

}



# 数据流分析小结

- 应用单调框架设计一个数据流分析包含如下内容
  - 设计每个结点附加值的定义域
  - 设计交汇函数
  - 设计从语句导出结点变换函数的方法
  - 入口结点的初值
- 需要证明如下内容
  - 在单条路径上，变换函数保证安全性
  - 交汇函数对多条路径的合并方式保证安全性
  - 交汇函数形成一个半格
  - 半格的高度有限
    - 通常通过结点附加值的定义域为有限集合证明
  - 变换函数均为单调函数
    - 通常定义为 $f(D) = (D - KILL) \cup GEN$ 的形式



# 参考资料

- 《编译原理》 第9章
- Lecture Notes on Static Analysis
  - <https://cs.au.dk/~amoeller/spa/>