



软件分析

Steensgaard算法和 过程间指针分析

熊英飞
北京大学

2018



复习：Anderson指向分析算法填空

赋值语句	约束
$a = \&b$	$a \supseteq \{b\}$
$a = b$	
$a = *b$	
$*a = b$	

复习：Anderson指向分析算法填空



赋值语句	约束
$a = \&b$	$a \supseteq \{b\}$
$a = b$	$a \supseteq b$
$a = *b$	$\forall v \in b. a \supseteq v$
$*a = b$	$\forall v \in a. v \supseteq b$



Steensgaard指向分析算法

- Anderson算法的复杂度为 $O(n^3)$
- Steensgaard指向分析通过牺牲精确性来达到效率
- 分析复杂度为 $O(n\alpha(n))$ ，接近线性时间。
 - n 为程序中的语句数量。
 - α 为阿克曼函数的逆
 - $\alpha(2^{132}) < 4$



Steensgaard指向分析算法

- Anderson算法执行速度较慢的一个重要原因是边数就达到 $O(n^2)$ 。
- 边数较多的原因是因为*p的间接访问会导致动态创建边
- Steensgaard算法通过不断合并同类项来保证间接访问可以一步完成，不用创建边



Steensgaard指向分析算法

```
o=&v;  
q=&p;  
if (a > b) {  
    p=*&q;  
    p=o; }  
*q=&w;
```

- 产生约束

- $v \in o$
- $p \in q$
- $p =^* q$
- $p = o$
- $w \in^* q$
- $\forall y. \forall x \in y. x =^* y$

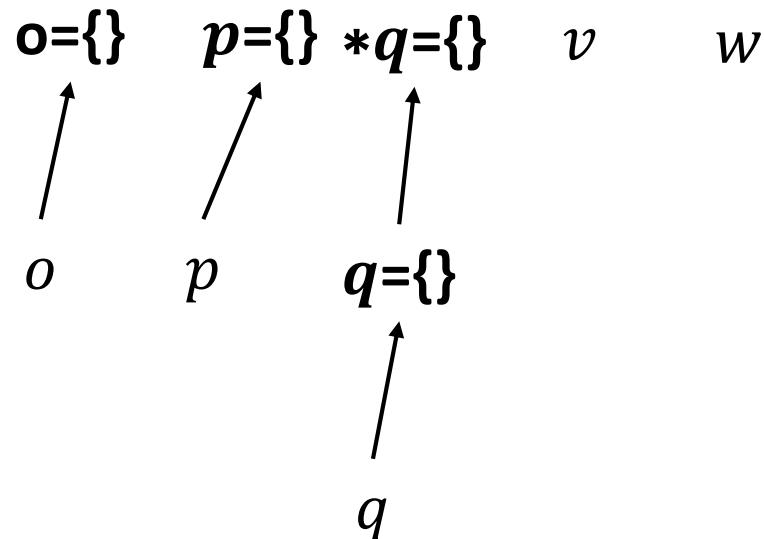
通用约束，
用于传递
相等关系

- 赋值使得左右两边的集合相等
- 最后一条约束使得相等指针的后继也相等
- 因为集合相等，所以只需要一个集合来表示
- 每个等号约束都是集合的合并



合并操作执行方法

- $v \in o$
- $p \in q$
- $p = {}^* q$
- $p = o$
- $w \in {}^* q$
- $\forall y. \forall x \in y. x = {}^* y$

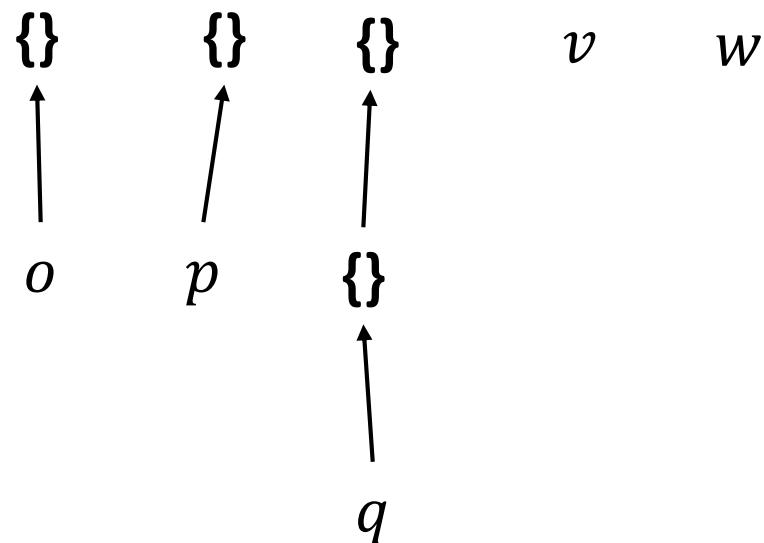


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

- $v \in o$
- $p \in q$
- $p = {}^* q$
- $p = o$
- $w \in {}^* q$
- $\forall y. \forall x \in y. x = {}^* y$

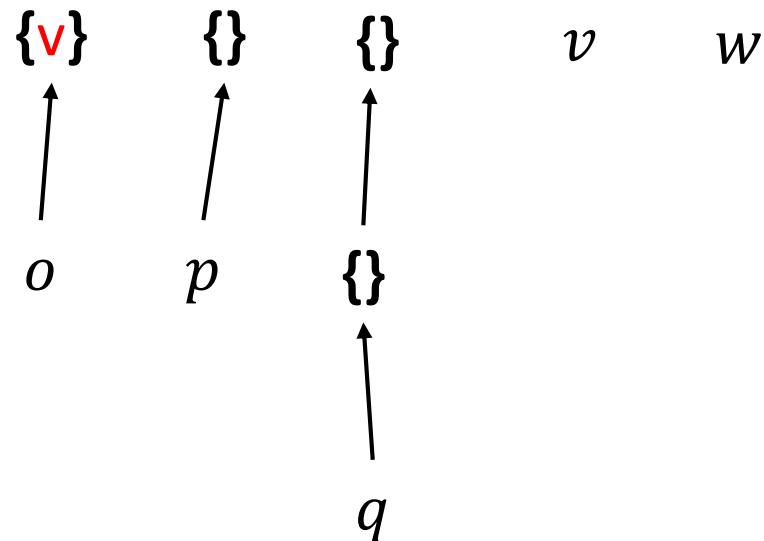


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

- $v \in o$
- $p \in q$
- $p =^* q$
- $p = o$
- $w \in^* q$
- $\forall y. \forall x \in y. x =^* y$

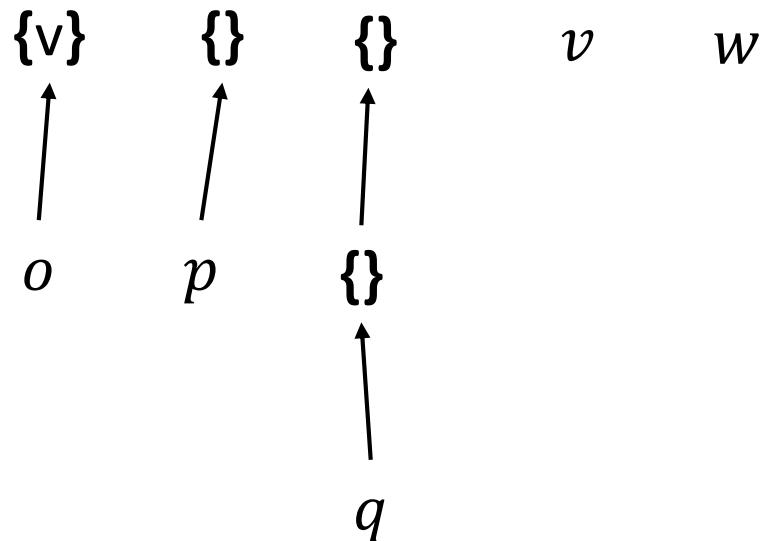


对于集合和元素的合并，添加元素到集合中，并添加元素的后继为集合的后继



合并操作执行方法

- $v \in o$
- $p \in q$
- $p = {}^* q$
- $p = o$
- $w \in {}^* q$
- $\forall y. \forall x \in y. x = {}^* y$

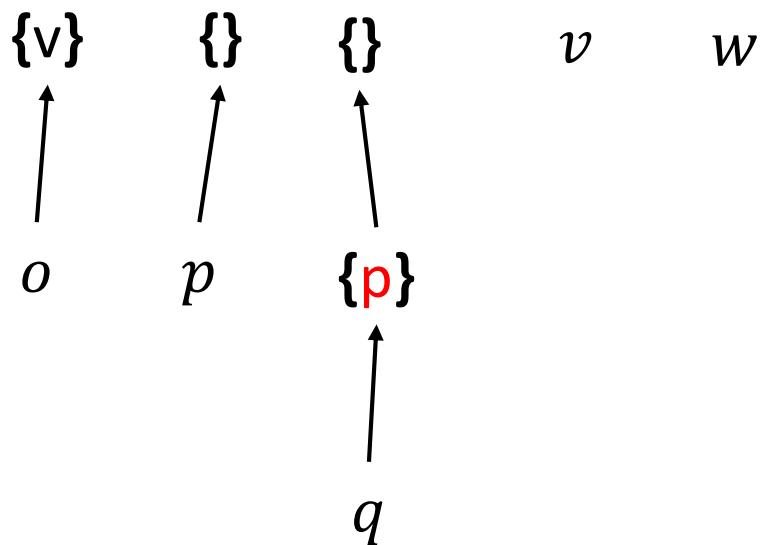


对于集合和元素的合并，添加元素到集合中，并添加元素的后继为集合的后继



合并操作执行方法

- $v \in o$
- $p \in q$
- $p = {}^* q$
- $p = o$
- $w \in {}^* q$
- $\forall y. \forall x \in y. x = {}^* y$

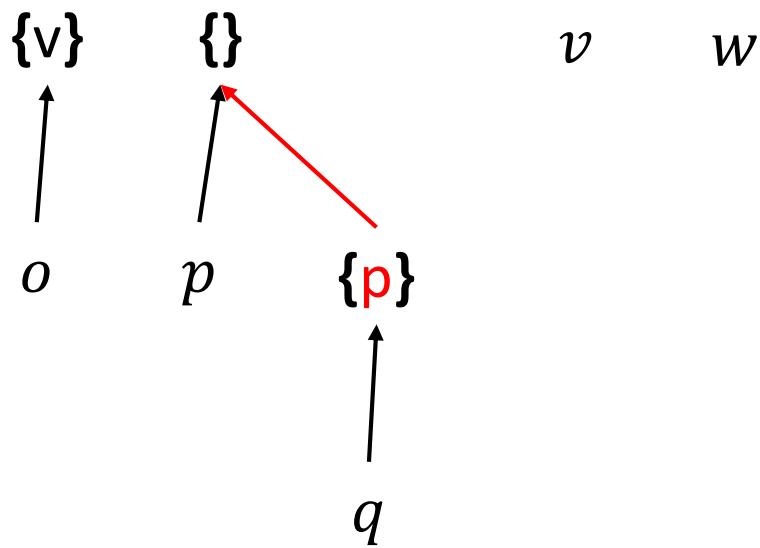


对于集合和元素的合并，添加元素到集合中，并添加元素的后继为集合的后继



合并操作执行方法

- $v \in o$
- $p \in q$
- $p =^* q$
- $p = o$
- $w \in^* q$
- $\forall y. \forall x \in y. x =^* y$

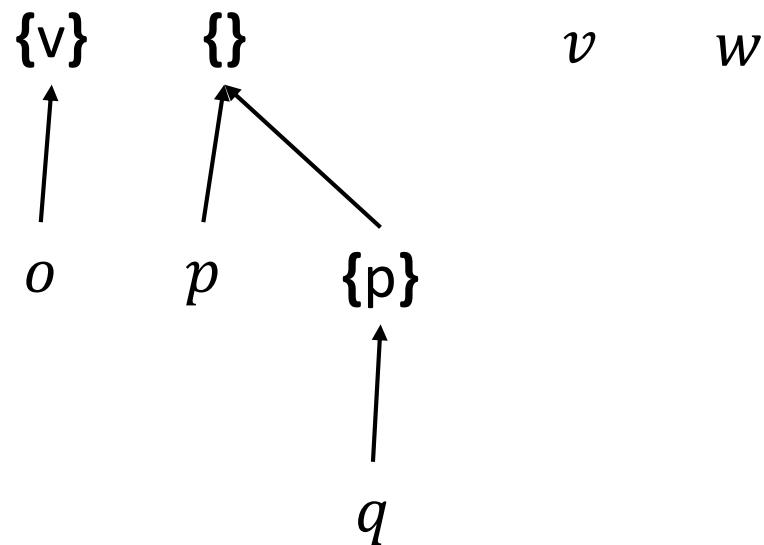


继续合并后继



合并操作执行方法

- $v \in o$
- $p \in q$
- $\textcolor{red}{p =^* q}$
- $p = o$
- $w \in^* q$
- $\forall y. \forall x \in y. x =^* y$

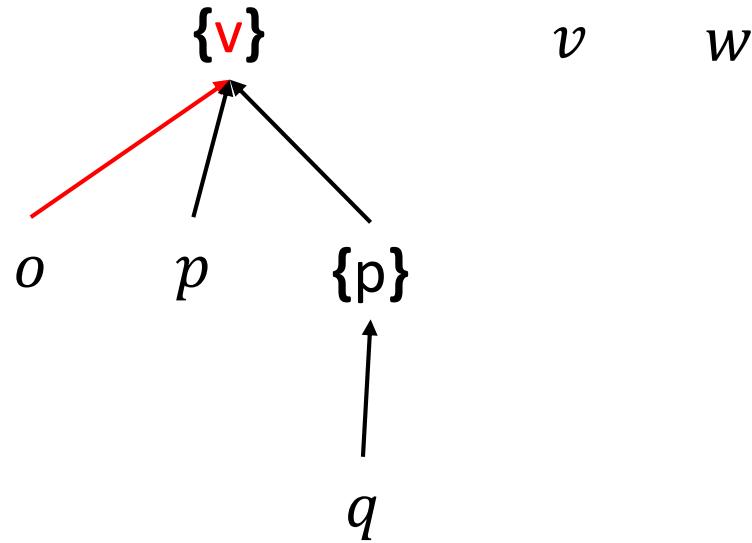


对于集合的合并，直接合并两个集合



合并操作执行方法

- $v \in o$
- $p \in q$
- $p =^* q$
- $\textcolor{red}{p = o}$
- $w \in ^* q$
- $\forall y. \forall x \in y. x =^* y$

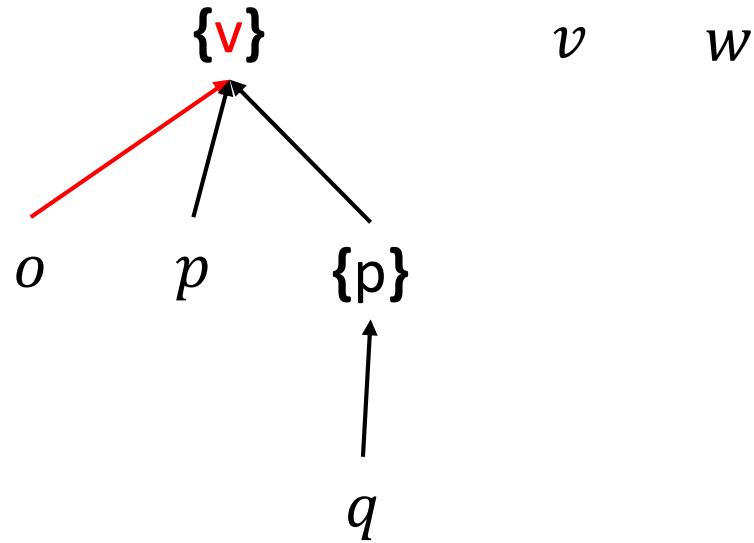


对于集合的合并，直接合并两个集合



合并操作执行方法

- $v \in o$
- $p \in q$
- $p =^* q$
- $p = o$
- $w \in^* q$
- $\forall y. \forall x \in y. x =^* y$

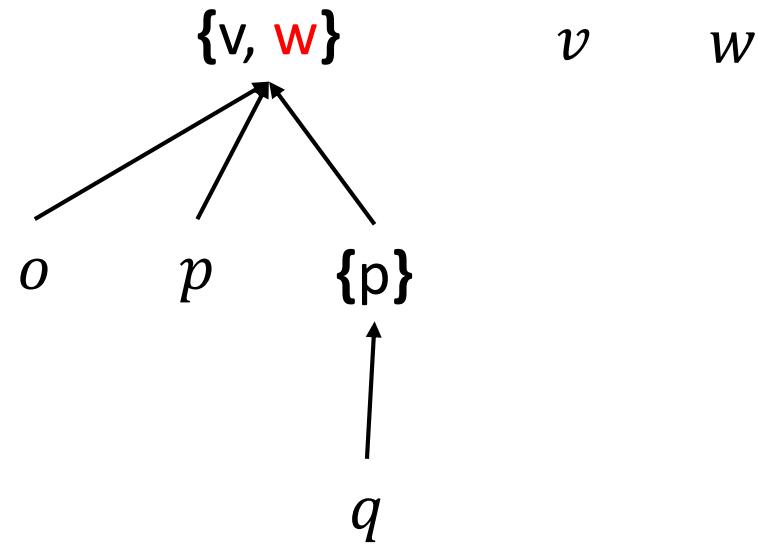


对于集合的合并，直接合并两个集合



合并操作执行方法

- $v \in o$
- $p \in q$
- $p = {}^* q$
- $p = o$
- $w \in {}^* q$
- $\forall y. \forall x \in y. x = {}^* y$



- 返回
 - $p = \{v, w\}$
 - $q = \{p\}$
 - $o = \{v, w\} // \text{不精确}$



复杂度分析

- 节点个数为 $O(n)$
- 每次合并会减少一个节点，所以总合并次数是 $O(n)$
- 每次合并的时间开销包括
 - 集合的合并开销
 - 解析*p等指针引用找到合适集合的开销
- 通过选择合适的数据结构（union-find structure），可以做到 $O(1)$ 时间的合并和 $O(\alpha(n))$ 的查找



术语

- Inclusion-based
 - 指类似Anderson方式的指针分析算法
- Unification-based
 - 指类似Steensgaard方式的指针分析算法



别名分析

- 给定两个变量 a, b , 判断这两个变量是否指向相同的内存位置, 返回以下结果之一
 - a, b 是must aliases: 始终指向同样的位置
 - a, b 是must-not aliases: 始终不指向同样的位置
 - a, b 是may aliases: 可能指向同样的位置, 也可能不指向
- 别名分析结果可以从指向分析导出
 - 如果 $a=b$ 且 $|a|=1$, 则 a 和 b 为must aliases
 - 如果 $a \cap b = \emptyset$, 则 a 和 b 为must-not aliases
 - 否则 a 和 b 为may aliases
- 别名分析本身有更精确的算法, 但可伸缩性不高, 在实践中较少使用



上下文敏感的指针分析

- 能否做精确的上下文敏感的指针分析？
- 域敏感的指针分析或者考虑二级指针的分析：不能
- 简单理论理解
 - 上下文无关性是一个上下文无关属性
 - 必须用下推自动机表示
 - 域敏感性也是一个上下文无关属性
 - 两个上下文无关属性的交集不一定是上下文无关属性
- Tom Reps等人2000年证明这是一个不可判定问题



解决方法

- 降低上下文敏感性：把被调方法根据上下文克隆n次
- 降低域敏感性：把域展开n次



域展开一次

```
Struct Node {  
    int value;  
    Node* next;  
};
```

```
a = malloc();  
a->next = b;
```

- 对于每个 Node^* 的变量 a , 创建两个指针变量
 - a
 - $a \rightarrow \text{next}$
- $a \rightarrow \text{next} = b$ 产生
 - $a \rightarrow \text{next} \supseteq b$
 - $a \rightarrow \text{next} \supseteq b \rightarrow \text{next}$
- $a = b \rightarrow \text{next}$ 产生
 - $a \supseteq b \rightarrow \text{next}$
 - $a \rightarrow \text{next} \supseteq b \rightarrow \text{next}$

约束中不含全程量词，可以用IFDS转成图并加上括号。



域展开两次

```
Struct Node {  
    int value;  
    Node* next;  
};  
a = malloc();  
a->next = b;
```

- 对于每个**Node***的变量a， 创建两个指针变量
 - a
 - a->next
 - a->next->next
- a->next=b产生
 - a->next \supseteq b
 - a->next->next \supseteq b->next
 - a->next->next \supseteq b->next->next
- a=b->next产生
 - a \supseteq b->next
 - a->next \supseteq b->next->next
 - a->next->next \supseteq b->next->next



过程间分析-函数指针

```
interface I {  
    void m();  
}  
  
class A implements I {  
    void m() { x = 1; }  
}  
  
class B implements I {  
    void m() { x = 2; }  
}  
  
static void main() {  
    I i = new A();  
    i.m();  
}
```

如何设计分析算法得出程序执行结束后的x所有可能的值？



控制流分析

- 确定函数调用目标的分析叫做控制流分析
- 控制流分析是may analysis
 - 为什么不是must analysis?
- 控制流分析 vs 数据流分析
 - 控制流分析确定程序控制的流向
 - 数据流分析确定程序中数据的流向
 - 数据流分析在控制流图上完成，因此控制流分析是数据流分析的基础



Class Hierarchy Analysis

```
interface I {  
    void m(); }  
class A implements I {  
    void m() { x = 1; } }  
class B implements I {  
    void m() { x = 2; } }  
static void main() {  
    I i = new A();  
    i.m(); }  
class C { void m() {} }
```

- 根据*i*的类型确定*m*可能的目标
- 在这个例子中，*i.m*可能的目标为
 - *A.m()*
 - *B.m()*
- 不可能的目标为
 - *C.m()*
- 分析结果为*x={1,2}*
- 优点：简单快速
- 缺点：非常不精确，特别是有*Object.equals()*这类调用的时候



Rapid Type Analysis

```
interface I {  
    void m(); }  
class A implements I {  
    void m() { x = 1; } }  
class B implements I {  
    void m() { x = 2; } }  
static void main() {  
    I i = new A();  
    i.m(); }  
class C { void m() {  
    new B().m(); } }
```

- 只考慮那些在程序中创建了的对彖
- 可以有效过滤library中的大量没有使用的类



Rapid Type Analysis

```
interface I {  
    void m(); }  
class A implements I {  
    void m() { x = 1; } }  
class B implements I {  
    void m() { x = 2; } }  
static void main() {  
    I i = new A();  
    i.m(); }  
class C { void m() {  
    new B().m();  
} }
```

- 三个集合
 - 程序中可能被调用的方法集合**Methods**, 初始包括**main**
 - 程序中所有的方法调用和对应目标 **Calls→Methods**
 - 程序中所有可能被使用的类**Classes**
- **Methods**中每增加一个方法
 - 将该方法中所有创建的类型加到**Classes**
 - 将该方法中所有的调用加入到**Call**, 目标初始为根据当前**Classes**集合类型匹配的方法
- **Classes**中每增加一个类
 - 针对每一次调用, 如果类型匹配, 把该类中对应的方法加入到**Calls→Methods**
 - 把方法加入到**Methods**当中



Rapid Type Analysis

```
interface I {  
    void m(); }  
class A implements I {  
    void m() { x = 1; } }  
class B implements I {  
    void m() { x = 2; } }  
static void main() {  
    I i = new A();  
    I j = new B();  
    i.m(); }  
  
class C { void m() {  
    new B().m();  
} }
```

- 分析速度非常快
- 精度仍然有限
- 在左边的例子中，得出i.m的目标包括A.m和B.m
- 如何进一步分析出精确的结果？



精确的控制流分析CFA

- 该算法没有名字，通常直接称为CFA (control flow analysis)
- CFA和指针分析需要一起完成
 - 指针分析确定调用对象
 - 调用对象确定新的指向关系
- 原始算法定义在 λ 演算上
- 这里介绍算法的面向对象版本



CFA-算法

```
interface I {  
    I m();}  
  
class A implements I {  
    I m() { return new B(); } }  
  
class B implements I {  
    I m() { return new A(); } }  
  
static void main() {  
    I i = new A();  
    if (...) i = i.m();  
    I x = i.m();  
}
```

- 首先每个方法的参数和返回值都变成图上的点
 - 注意this指针是默认参数
- 对于方法调用
 - $f() \{ \dots \}$
 - $x = y.g(a, b)$
 - $\dots \}$
- 生成约束
 - $\forall y \in f\#y. \forall m \in \text{targets}(y, g), f\#x \supseteq m\#\text{ret}$
 - $m\#\text{this} \supseteq \text{filter}(f\#y, \text{declared}(m))$
 - $m\#a \supseteq f\#a$
 - $m\#b \supseteq f\#b$
- 约束求解方法和Anderson指针分析
算法类似

根据调用对象
和方法名确定
被调用方法

方法的声明类

保留符合特定
类型的对象



CFA-计算示例

```
interface I {  
    I f(); }  
  
class A implements I {  
    I f() { return new B1(); } }  
  
class B implements I {  
    I f() { return new A2(); } }  
  
static void main() {  
    I i = new A3();  
    if (...) i = i.f();  
    I x = i.f();  
}
```

- **main#i** $\supseteq \{3\}$
- $\forall i \in \text{main}\#i, \forall m \in \text{targets}(i, f),$
 - **main#i** $\supseteq m\#\text{ret}$
 - **m#this** \supseteq
filter(**main#i**, declared(m))
- $\forall i \in \text{main}\#i, \forall m \in \text{targets}(i, f),$
 - **main#x** $\supseteq m\#\text{ret}$
 - **mthis** \supseteq filter (**main#i**, declared(m))
- **A.f#ret** $\supseteq \{1\}$
- **B.f#ret** $\supseteq \{2\}$
-
- 求解结果
 - **main#i** = {1, 2, 3}
 - **main#x** = {1, 2}



CFA

- 以上CFA算法是否是上下文敏感的？
- 不是，因为每个方法只记录了一份信息，没有区分上下文
- 用克隆的方法处理上下文敏感性
- 基于克隆方法的CFA也被称为m/k-CFA
 - 上下文不敏感的CFA称为0-CFA



流敏感vs上下文敏感

- 当不能同时做到两种精度时，优先考虑哪个？
 - 通常认为，在C语言等传统命令式语言中流敏感性比较重要
 - 在Java、C++等面向对象语言中上下文敏感性比较重要
 - 主流指针分析算法通常时上下文敏感而流非敏感的



Soot

- Java环境需求: Java 8 (下载页:
<https://www.oracle.com/technetwork/java/javase/downloads/index.html>)
- Soot下载: (<https://soot-build.cs.uni-paderborn.de/public/origin/master/soot/soot-master/3.1.0/build/sootclasses-trunk-jar-with-dependencies.jar>)
- 一个顺手的Java开发环境 (演示会使用IntelliJ IDEA)