



软件分析

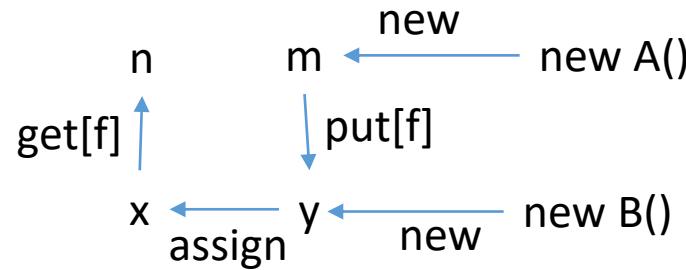
其他过程内指针分析 过程间指针分析

熊英飞
北京大学



基于CFL可达性的域敏感分析

```
y = new B();  
m=new A();  
x=y;  
y.f=m;  
n=x.f;
```



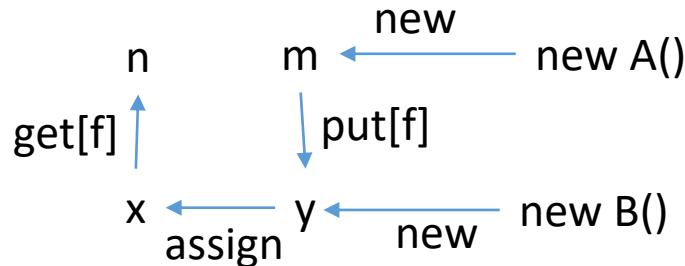
图上的每条边f同时存在反向边f

```
FlowTo= new (assign | put[f] Alias get[f])*  
PointsTo = (assign | get[f] Alias put[f])* new  
Alias = PointsTo FlowTo
```



基于CFL可达性的域敏感分析

```
y = new B();
m=new A();
x=y;
y.f=m;
n=x.f;
```



图上的每条边 f 同时存在反向边 f

$\text{FlowTo} = \text{new} (\text{assign} \mid \text{put}[f] \text{ Alias } \text{get}[f])^*$
 $\text{PointsTo} = (\underline{\text{assign}} \mid \underline{\text{get}[f]} \text{ Alias } \underline{\text{put}[f]})^* \underline{\text{new}}$
 $\text{Alias} = \text{PointsTo FlowTo}$

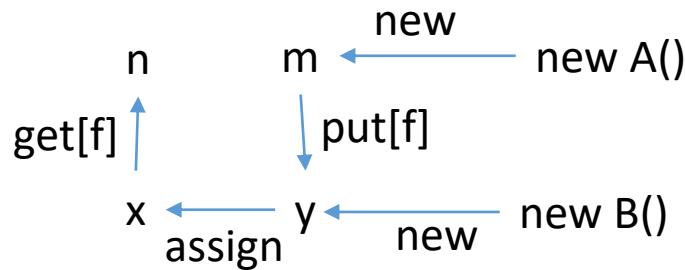
能否不定义Alias关系？比如：

$\text{FlowTo} = \text{new FlowTo}'$
 $\text{FlowTo}' = \text{put}[f] \text{ FlowTo}' \text{ get}[f]$
 $\quad \mid \text{FlowTo}' \text{ FlowTo}' \mid \text{assign} \mid \epsilon$



基于CFL可达性的域敏感分析

```
y = new B();
m=new A();
x=y;
y.f=m;
n=x.f;
```



图上的每条边 f 同时存在反向边 f

$\text{FlowTo} = \text{new } (\text{assign} \mid \text{put}[f] \text{ Alias get}[f])^*$
 $\text{PointsTo} = (\underline{\text{assign}} \mid \underline{\text{get}[f]} \text{ Alias } \underline{\text{put}[f]})^* \underline{\text{new}}$
 $\text{Alias} = \text{PointsTo FlowTo}$

能否把`assign`统一定义在`Alias`内部？如：

$\text{FlowTo} = \text{new } (\text{Alias} \mid \text{put}[f] \text{ Alias get}[f])^*$
 $\text{PointsTo} = (\text{Alias} \mid \underline{\text{get}[f]} \text{ Alias } \underline{\text{put}[f]})^* \underline{\text{new}}$
 $\text{Alias} = \text{PointsTo FlowTo} \mid \text{assign} \mid \underline{\text{assign}}$



基于CFL和基于Anderson算法的域敏感分析等价性

基于CFL	基于Anderson算法
$x \xrightarrow{\text{PointsTo}} m$	$m \in x$
$m \xrightarrow{\text{FlowsTo}} x$	$m \in x$
$x \xrightarrow{\text{Alias}} y$	$x \cap y \neq \emptyset$
$\exists y. y \xrightarrow{\text{PointsTo}} n \wedge y \xrightarrow{\text{puts}[f]} \xrightarrow{\text{PointsTo}} m$	$n \in m.f$

归纳证明 以上各行左右的等价性

- 从左边推出右边：在CFL的路径长度上做归纳
- 从右边推出左边：在集合的元素个数上做归纳

复习： Anderson指向分析算法



$o = \&v;$

- 产生约束

$q = \{\}$

$w = \&w;$

- $o \supseteq \{v\}$
- $w \supseteq \{w\}$
- $q \supseteq \{p\}$
- $q \supseteq \{r\}$

$p = \{\}$

$q = \&p;$

if ($a > b$) {

- $\forall v \in q. v \supseteq p$
- $\forall v \in q. w \supseteq v$
- $p \supseteq o$

$o = \{\}$

$q = \&r;$

$*q = p;$

$w = *q;$

$p = o; \}$

$w = \{\}$

$r = \{\}$

复习： Anderson指向分析算法



$o = \&v;$

- 产生约束

$q = \{pr\}$

$w = \&w;$

- $o \supseteq \{v\}$
- $w \supseteq \{w\}$
- $q \supseteq \{p\}$
- $q \supseteq \{r\}$

$p = \{\}$

$q = \&p;$

if ($a > b$) {

$q = \&r;$

$*q = p;$

$w = *q;$

$p = o; }$

- $\forall v \in q. v \supseteq p$
- $\forall v \in q. w \supseteq v$
- $p \supseteq o$

$o = \{v\}$

$w = \{w\}$

$r = \{\}$

复习：Anderson指向分析算法



$o = \&v;$

$w = \&w;$

$q = \&p;$

if ($a > b$) {

$q = \&r;$

$*q = p;$

$w = *q;$

$p = o;$ }

- 产生约束

- $o \supseteq \{v\}$
- $w \supseteq \{w\}$
- $q \supseteq \{p\}$
- $q \supseteq \{r\}$
- $\forall v \in q. v \supseteq p$
- $\forall v \in q. w \supseteq v$
- $p \supseteq o$

$q = \{pr\}$

$p = \{\}$

$o = \{v\}$

$w = \{w\}$

$r = \{\}$

复习：Anderson指向分析算法



$o = \&v;$

$w = \&w;$

$q = \&p;$

if ($a > b$) {

$q = \&r;$

$*q = p;$

$w = *q;$

$p = o;$ }

- 产生约束

- $o \supseteq \{v\}$
- $w \supseteq \{w\}$
- $q \supseteq \{p\}$
- $q \supseteq \{r\}$
- $\forall v \in q. v \supseteq p$
- $\forall v \in q. w \supseteq v$
- $p \supseteq o$

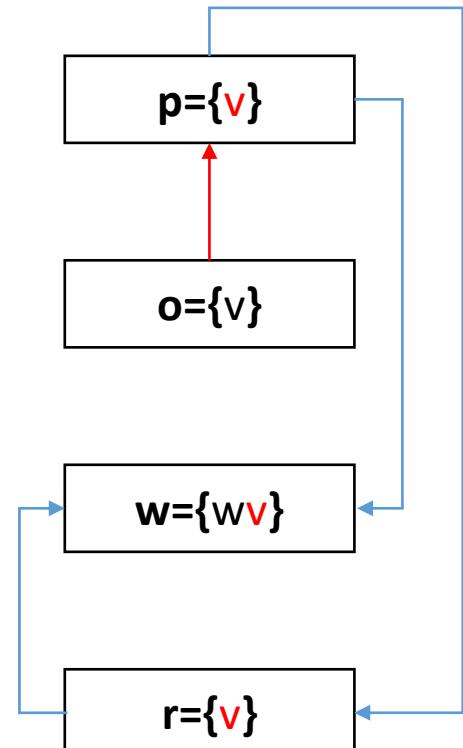
$q = \{pr\}$

$p = \{v\}$

$o = \{v\}$

$w = \{wv\}$

$r = \{v\}$





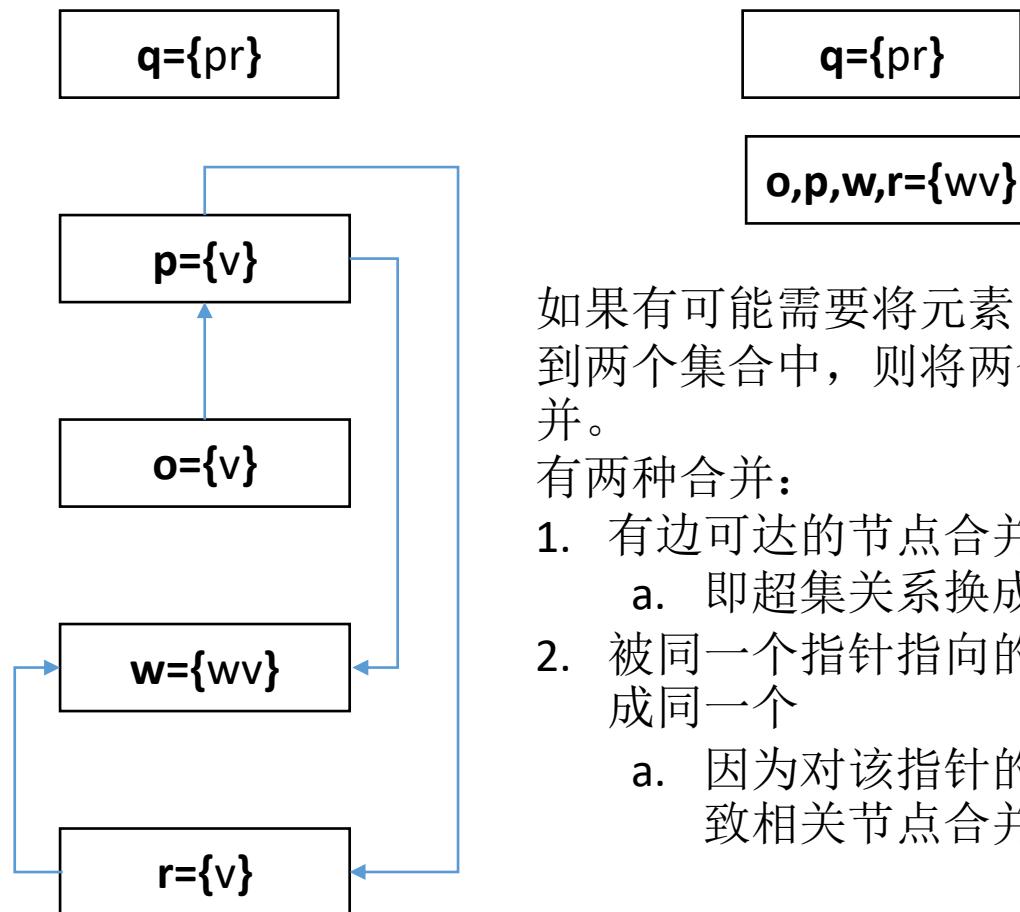
Steensgaard指向分析算法

- Anderson算法的开销主要来自于顺着边传递地址
 - 复杂度为 $O(n^3)$
- 取消一部分传递能显著提升效率
 - The Ant and the Grasshopper: Fast and Accurate Pointer Analysis for Millions of Lines of Code, Hardekopf and Lin, PLDI 2007
- 能否通过牺牲精度来彻底取消这个传递?
- Steensgaard指向分析算法
 - 通过合并节点避免传递
 - 复杂度为 $O(n\alpha(n))$, 接近线性时间



Steensgaard指向分析结果

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



如果有可能需要将元素同时添加到两个集合中，则将两个集合合并。

有两种合并：

1. 有边可达的节点合并成同一个。
 - a. 即超集关系换成等价关系
2. 被同一个指针指向的节点合并成同一个
 - a. 因为对该指针的读写会导致相关节点合并



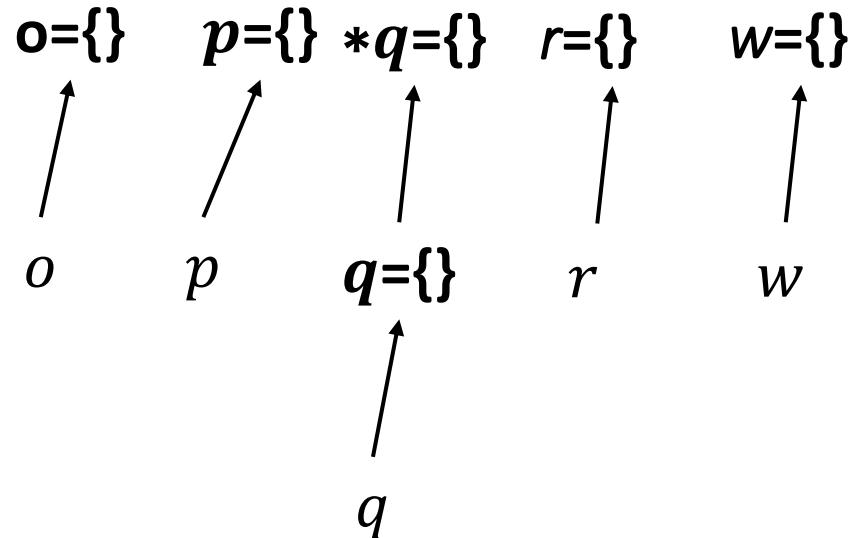
Steensgaard指向分析算法

- | | | |
|--------------------|---|--------------------------------|
| • $o = \&v;$ | • Anderson约束 | • Steensgaard约束 |
| • $w = \&w;$ | $\bullet o \supseteq \{v\}$ | $\bullet v \in o$ |
| • $q = \&p;$ | $\bullet w \supseteq \{w\}$ | $\bullet w \in w$ |
| • if ($a > b$) { | $\bullet q \supseteq \{p\}$ | $\bullet p \in q$ |
| • $q = \&r;$ | $\bullet q \supseteq \{r\}$ | $\bullet r \in q$ |
| • $*q = p;$ | $\bullet \forall v \in q. v \supseteq p$ | $\bullet *q = p$ |
| • $w = *q;$ | $\bullet \forall v \in q. w \supseteq v$ | $\bullet w = *q$ |
| • $p = o; }$ | $\bullet p \supseteq o$ | $\bullet p = o$ |
| | <ul style="list-style-type: none">• 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，所以可以合并成一个集合 | <p>通用约束，
用于传递
相等关系</p> |



合并操作执行方法

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

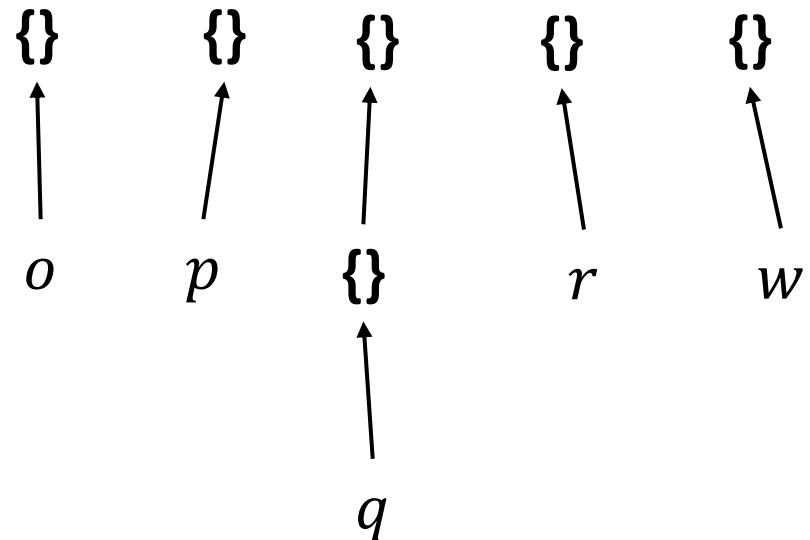


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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

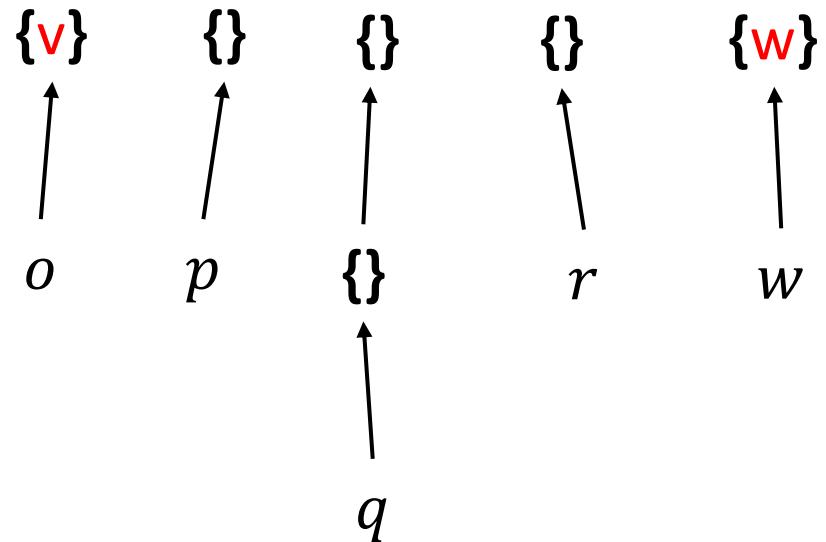


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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

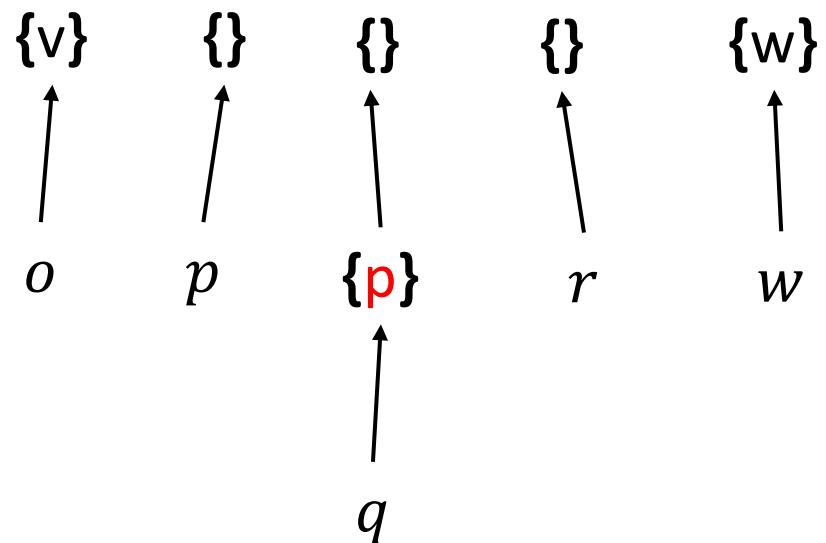


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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

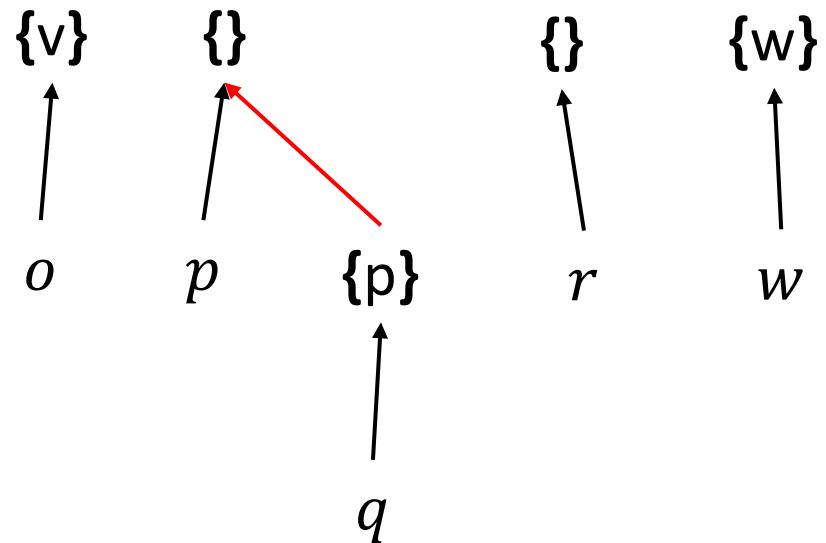


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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

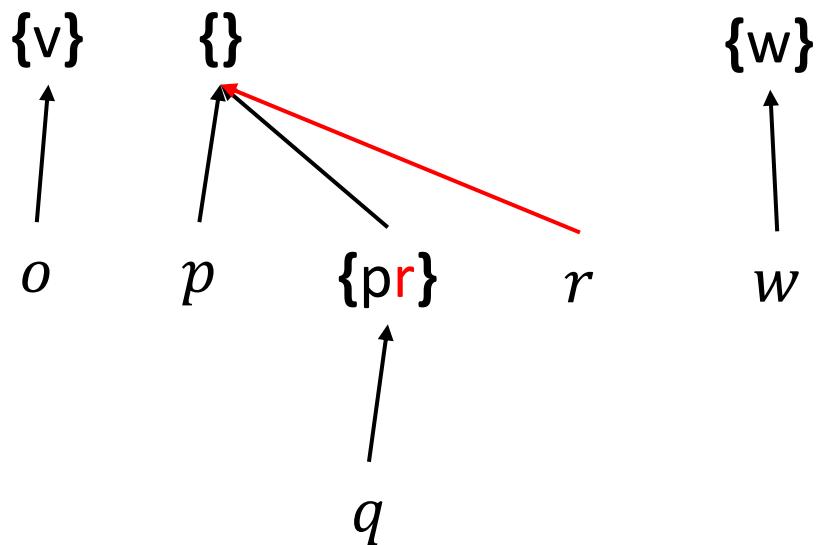


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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

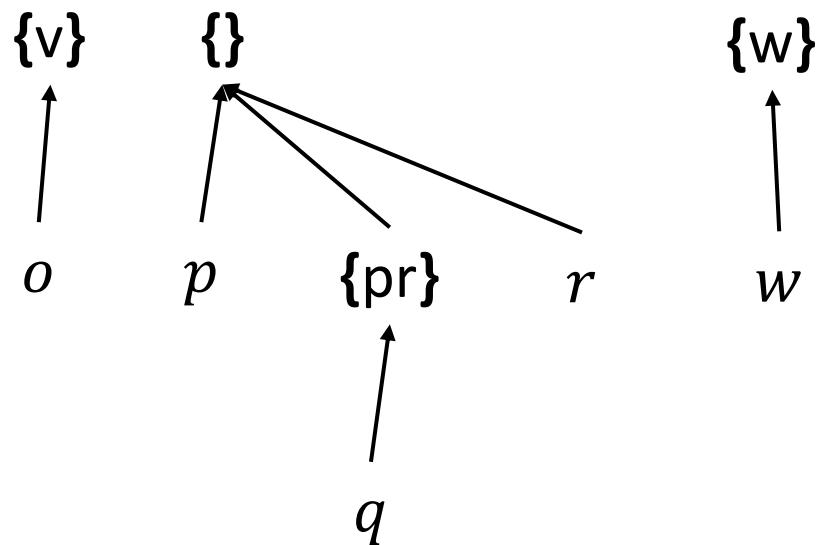


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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

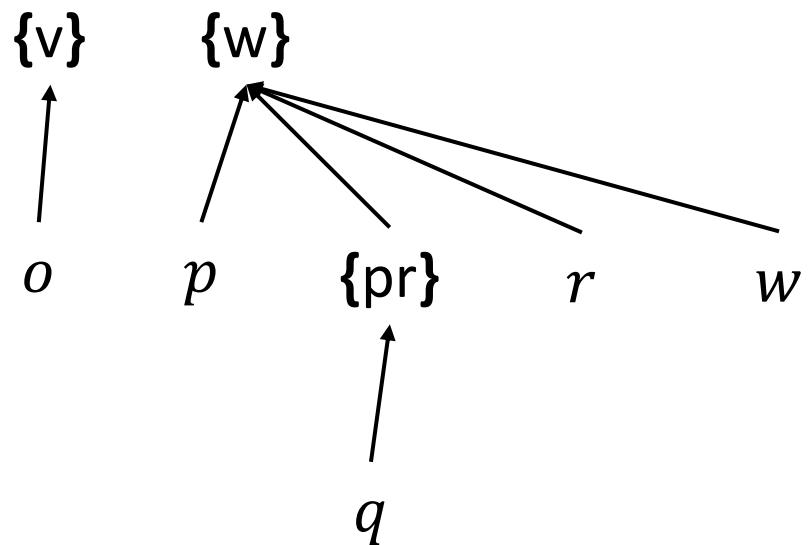


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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

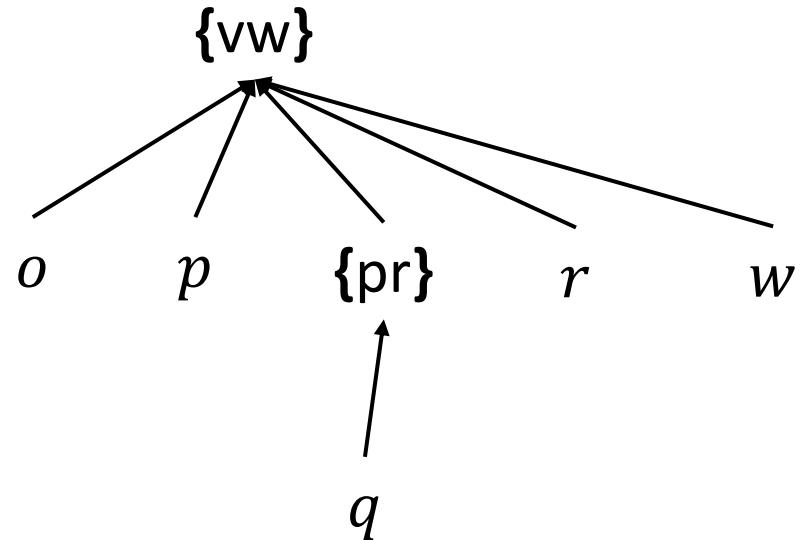


- 边表示指向关系
- 每个元素只能有一个后继
- 如果合并导致多于一个后继，就合并后继



合并操作执行方法

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



- 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



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 $O(n)$
- 通过并查集实现合并，单次合并的开销为 $O(\alpha(n))$



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



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



降低上下文敏感性

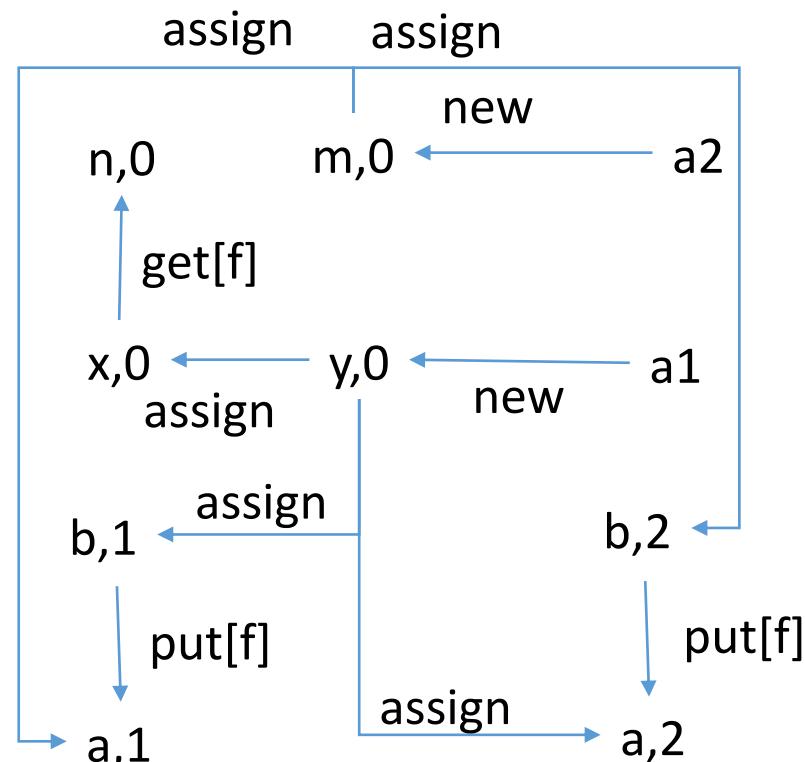
FlowTo= new (assign | put[f] Alias get[f])*

PointsTo = (assign | get[f] Alias put[f])* new

Alias = PointsTo FlowTo

```
Main(): //0  
y = new A(); //a1  
m=new A(); //a2  
SetF(m, y); //1  
x=y;  
SetF(y, m); //2  
n=x.f;
```

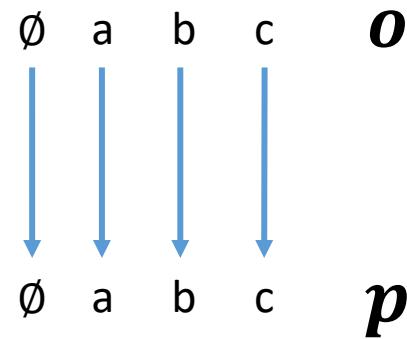
```
SetF(a, b):  
a.f=b;
```





降低域敏感性

- 思路：转换成CFL可达性问题来进行精确的上下文敏感分析
- 对于约束 $p \supseteq o$
- 化为方程 $p = p \cup o$
 - 或看做转换函数 $f(p, o) = p \cup o$
- 即如下可达性图





降低域敏感性

- 但是，原分析中还有全称量词
 - $\forall x \in a, x.\mathbf{next} \supseteq b$
- 这类约束无法直接转换成CFL可达性的图表示
 - 需要在图上动态加边
- 通过降低域敏感性来去掉全称量词



复习：域非敏感分析

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

- 把所有struct中的所有fields当成一个对象
- 原程序变为
 - $a' = \text{malloc}();$
 - $a' = b;$
 - $a' = c;$
 - 其中 a' 代表 a , $a->\text{next}$, $a->\text{prev}$
- 约束中不会出现全称量词



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
 - $a \rightarrow \text{next}$
- $a = b$ 产生
 - $a \supseteq b$
 - $a \rightarrow \text{next} = b \rightarrow \text{next}$
- $a \rightarrow \text{next} = b$ 产生
 - $a \rightarrow \text{next} \supseteq b$
 - $a \rightarrow \text{next} = b \rightarrow \text{next}$
- $a = b \rightarrow \text{next}$ 产生
 - $a \supseteq b \rightarrow \text{next}$
 - $a \rightarrow \text{next} = b \rightarrow \text{next}$

能不能
换成 \supseteq

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 ⊇ b`
 - `a->next->next = b->next`
 - `a->next->next = b->next->next`
- `a=b->next` 产生
 - `a ⊇ b->next`
 - `a->next = b->next->next`
 - `a->next->next = b->next->next`



域敏感性 vs 上下文敏感性

- 目前学术界还缺乏对两者权衡的详细比较
 - 降低上下文敏感性和降低域敏感性的研究各自独立发展，需要进一步工作进行统一
- 降低上下文敏感性的工作
 - 通常基于CFL可达性的指向分析，通过引入新的表示和算法来尽量精确的进行上下文敏感分析
 - 如：用正则文法来模拟上下文敏感性所需的上下文无关文法
 - 参考：Manu Sridharan, Rastislav Bodík: Refinement-based context-sensitive points-to analysis for Java. PLDI 2006: 387-400
- 降低域敏感性的工作
 - 通常基于Anderson指向分析，通过引入新的表示和算法来尽量精确的进行域敏感分析
 - 如：引入*表示任意长的访问序列
 - 参考：Johannes Lerch, Johannes Späth, Eric Bodden, Mira Mezini: Access-Path Abstraction: Scaling Field-Sensitive Data-Flow Analysis with Unbounded Access Paths (T). ASE 2015: 619-629
- 主流框架中更多采用精确域敏感性，用克隆实现上下文敏感性的方法



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

- **main#i ⊨{3}**
- $\forall i \in \text{main}\#i, \forall m \in \text{targets}(i, f),$
 - **main#i ⊨ m#ret**
 - **m#this ⊨ filter(main#i, declared(m))**
- $\forall i \in \text{main}\#i, \forall m \in \text{targets}(i, f),$
 - **main#x ⊨ m#ret**
 - **mthis ⊨ filter (main#i, declared(m))**
- **A.f#ret ⊨{1}**
- **B.f#ret ⊨{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是上下文敏感而流非敏感的



参考文献

- 基于CFA的指向分析：
 - Thomas W. Reps: Program Analysis via Graph Reachability. ILPS 1997: 5-19
- Steensgaard分析：
 - Lecture Notes: Pointer Analysis
 - Jonathan Aldrich
 - <https://www.cs.cmu.edu/~aldrich/courses/15-819O-13sp/resources/pointer.pdf>
- 控制流分析：
 - Lecture Notes: Object-Oriented Call Graph Construction
 - Jonathan Aldrich
 - <https://www.cs.cmu.edu/~aldrich/courses/15-819O-13sp/resources/callgraph.pdf>
- 基于展开域的指针分析：
 - Neil D. Jones, Steven S. Muchnick: Flow Analysis and Optimization of Lisp-Like Structures. POPL 1979: 244-256