

Universidade da Beira Interior

Desenho de Linguagens de Programação e de Compiladores

Simão Melo de Sousa

Aula 16 - Análise estática de programas com apontadores

- Introdução à análise estática de apontador
- Análise de Andersen
- Análise de Steensgaard
- Análise interprocedimental de apontador
- Análise de apontador nulo
- Análise de forma

Introdução à análise estática de apontador

como fazer, por exemplo, uma análise de propagação de constantes em programas que manipulam apontadores ou referências para objectos?


```
...
*x= 42;
*y= 87;
z = *x;
// será z igual a 42 ou 87 ?
```

```
E -> &x
| malloc
| *E
| null
| ...
| (E) (E ,..., E)
| ...
```

```
S -> *x = E;
| ...
```

os apontadores na linguagem de estudo (TIP) são limitados

- `malloc` aloca uma única célula, somente
- só estruturas lineares podem ser construídas na *heap*



ignoremos por enquanto os apontadores de funções

mesmo assim, há neste contexto, desafios interessantes para as análises estáticas

a questão fundamental sobre os apontadores é: **para que localizações podem apontar os apontadores?**

para responder, precisamos de uma abstracção adequada

o conjunto das células (abstractas) *Cell* contém

- *malloc-i* para cada local de alocação com índice *i*
- *x* para cada variável de nome *x* do programa

esta abstracção é conhecida como **abstracção dos locais de alocação** (*allocation site abstraction*)

o conjunto de todas os locais (abstractos), *Loc*, contém *&p* para cada célula *p*

cada célula abstracta pode corresponder a várias células de memória em tempo de execução

procura determinar para cada variável apontador x o **conjunto** $pt(x)$ **das células para as quais x pode apontar**

a análise é **conservadora** (*pode apontar para... - may point-to*)

- o conjunto pode ser abrangente demais
- pode mostrar a ausência de *aliasing*:
 $pt(x) \cap pt(y) = \emptyset$

```
...
*x= 42;
*y= 87;
z = *x;
// será z igual a 42
//ou 87 ?
```

concentremo-nos nas análises que não são sensíveis ao fluxo

- que se debruçam sobre a *AST*
- antes ou aquando da análise de fluxo de controlo

uma análise simples (*address taken analysis*) :

- incluir todas as células `malloc-i`
- incluir a célula `x` se a expressão `&x` ocorre no programa

no contexto de uma linguagem tipada, pode eliminar-se as células com tipos incompatíveis (com a variável apontador em causa)

para situações simples, a precisão desta análise é suficiente e é de facto computacionalmente bastante eficaz

precisamos de uma análise mais subtil para os casos menos triviais

preparemos o contexto para as análises que seguem:

assuma que todas as utilizações programáticas de apontadores são normalizadas

```
x=malloc  
x=&y  
x=y  
x=*y  
*x=y  
x=null
```

introduz muitas variáveis temporárias

mas agora todas as sub-expressões são simples (malloc, null ou nomes/localizações)

hipótese de trabalho: ignoramos o facto de as células criadas no momento da declaração e por malloc não são inicializadas

Análise de Andersen

para cada célula c , introduzimos uma variável de restrição $\llbracket c \rrbracket$ que toma valor sobre os conjuntos de localizações, i.e. $\llbracket . \rrbracket : Cell \rightarrow \mathcal{P}(Loc)$

$x = malloc$	$--\rightarrow$	$\&malloc-i \in \llbracket x \rrbracket$
$x = \&y$	$--\rightarrow$	$\&y \in \llbracket x \rrbracket$
$x = y$	$--\rightarrow$	$\llbracket y \rrbracket \in \llbracket x \rrbracket$
$x = *y$	$--\rightarrow$	$\&\alpha \in \llbracket y \rrbracket \implies \llbracket \alpha \rrbracket \in \llbracket x \rrbracket$
$*x = y$	$--\rightarrow$	$\&\alpha \in \llbracket x \rrbracket \implies \llbracket y \rrbracket \in \llbracket \alpha \rrbracket$
$x = null$	$--\rightarrow$	sem restrições

o mapa de apontadores (o mapa *points-to*) é definido como

$$pt(x) \triangleq \{\alpha \mid \&\alpha \in \llbracket x \rrbracket\}$$

as restrições geradas podem ser resolvidas pela framework cúbica!

a solução mínima única é dada em $\mathcal{O}(n^3)$

na prática, para Java (por exemplo), a complexidade é $\mathcal{O}(n^2)$

a análise é *flow-insentitive* mas é **dirigida** (sabemos em que direção os valores fluem nas atribuições)

restrições geradas

o programa em análise

```

var p,q,x,y,z;
p = malloc;
x = y;
x = z;
*p = z;
p = q;
q = &y;
x = *p;
p = &z;

```

$$\begin{array}{l}
& \& malloc - 1 \in \llbracket p \rrbracket \\
& \llbracket y \rrbracket \subseteq \llbracket x \rrbracket \\
& \llbracket z \rrbracket \subseteq \llbracket x \rrbracket \\
& \& \alpha \in \llbracket p \rrbracket \implies \llbracket z \rrbracket \subseteq \llbracket \alpha \rrbracket \\
& \llbracket q \rrbracket \subseteq \llbracket p \rrbracket \\
& \& y \in \llbracket q \rrbracket \\
& \& \alpha \in \llbracket p \rrbracket \implies \llbracket \alpha \rrbracket \subseteq \llbracket x \rrbracket \\
& \& z \in \llbracket p \rrbracket
\end{array}$$

menor solução

$$\begin{aligned}
pt(p) &= \{ malloc-1, y, z \} \\
pt(q) &= \{ y \}
\end{aligned}$$

mostre que a normalização dos programas previamente necessária à aplicação do algoritmo de Andersen pode ser automatizada com base na introdução adequada de variáveis temporárias frescas

Análise de Steensgaard

os mecanismos de resolução necessários a análise de Steengaard assentam nos mesmos princípios envolvidos na tipagem
revisitamos o algoritmo de tipagem visto aqui como uma *framework de unificação*

sobre a AST

para cada instrução/expressão E (incluido identificadores) temos o seu tipo como a solução de $\llbracket E \rrbracket$

assim

$intconst$	$\dashrightarrow \llbracket intcons \rrbracket = int$
$E_1 \text{ op } E_2$	$\dashrightarrow \llbracket E_1 \rrbracket = \llbracket E_2 \rrbracket = \llbracket E_1 \text{ op } E_2 \rrbracket = int$
$E_1 == E_2$	$\dashrightarrow \llbracket E_1 \rrbracket = \llbracket E_2 \rrbracket \text{ land } \llbracket E_1 \text{ op } E_2 \rrbracket = int$
$input$	$\dashrightarrow \llbracket input \rrbracket = int$
$x = E$	$\dashrightarrow \llbracket x \rrbracket = \llbracket E \rrbracket$
$output\ E;$	$\dashrightarrow \llbracket E \rrbracket = int$
$if\ (E)\{S\}$	$\dashrightarrow \llbracket E \rrbracket = int$
$if\ (E)\{S_1\}\ \text{else}\ \{S_2\}$	$\dashrightarrow \llbracket E \rrbracket = int$
$while\ (E)\{S\}$	$\dashrightarrow \llbracket E \rrbracket = int$

já sabemos que é possível generalizar para incluir subtipagem, polimorfismo, ordem superior, etc.

$f(p_1, \dots, p_n) \{ \dots \text{return } E; \}$	$\dashrightarrow \llbracket f \rrbracket = (\llbracket p_1 \rrbracket, \dots, \llbracket p_n \rrbracket) \rightarrow \llbracket E \rrbracket$
$(E)(E_1, \dots, E_n)$	$\dashrightarrow \llbracket E \rrbracket = (\llbracket E_1 \rrbracket, \dots, \llbracket E_n \rrbracket) \rightarrow \llbracket (E)(E_1, \dots, E_n) \rrbracket$
$\&x$	$\dashrightarrow \llbracket \&x \rrbracket = \&\llbracket x \rrbracket$
malloc	$\dashrightarrow \llbracket \text{malloc} \rrbracket = \&\alpha$
null	$\dashrightarrow \llbracket \text{null} \rrbracket = \&\alpha$
$*E$	$\dashrightarrow \llbracket E \rrbracket = \&\llbracket *E \rrbracket$
$*x = E$	$\dashrightarrow \llbracket x \rrbracket = \&\llbracket E \rrbracket$

de realçar que introduzimos uma variável de tipo α nas restrições

o problema da unificação trata das condições necessárias para igualar dois termos com variáveis

um termo (com variável) é construído com base em símbolos de função (designados por constructores) com respectiva aridade e símbolos de variáveis

por exemplo tendo os símbolos de funções a, b, c (aridade 0 - constantes), d, e (aridade 1), f, g, h (aridade 2), i, j, k (aridade 3)
 $a, d(a), h(a, g(d(a), b))$ são termos sem variáveis
 $f(X, b), h(X, g(Y, Z))$ são termos com variáveis

assim, concretamente um problema de unificação é encontrar a substituição ρ mais geral das variáveis (**most general unifier**) que permitam aos dois termos se tornarem sintaticamente iguais
por exemplo

$$k(X, bY) \stackrel{?}{=} k(f(Y, Z), Z, d(Z))$$

sim se $\rho = [X = f(d(b), b), Y = d(b), Z = b]$

não há soluções possíveis a um problema de unificação quando situações como as seguintes ocorram:

tentativa de identificação de símbolos de função diferentes

$$d(X) \stackrel{?}{\neq} e(X)$$

tentativa de identificação de termos com aridades erradas ou diferentes (eventualmente com os mesmo símbolo à cabeça)

$$a \stackrel{?}{\neq} a(X)$$

Unification theory


Franz Baader

Wayne Snyder

SECOND READERS: Patrick Narendran, Manfred Schmidt-Schauen, and Klaus Schulte

Contents

1	Introduction	401
1.1	What is unification?	401
1.2	History and applications	403
1.3	Approach	404
2	Syntactic unification	404
2.1	Definitions	404
2.2	Unification of terms	406
2.3	Unification of term dags	412
3	Equational unification	414
3.1	Basic notions	414
3.2	Free theorems	417
3.3	Instantiation	419
3.4	Theory of models for equational theories	420
4	Syntactic unification for disjunction	421
4.1	Unification in arbitrary theories	421
4.2	Unification in Σ -algebras in arbitrary theories	423
4.3	Unification	425
4.4	Unification and substitution of term rewriting	427
5	Heuristic approaches to Σ -unification	427
5.1	Unification modulo AC, ACU, and ACU in examples	428
5.2	The class of noncommutational theories	432
5.3	The corresponding rewriting	434
5.4	Results on decidability in commutational theories	435
6	Complexities of unification algorithms	437
6.1	A general unification method	438
6.2	Proving correctness of the unification method	441
7	Further topics	442
	Bibliography	443
	Index	444

HANDBOOK OF AUTOMATED REASONING
Edited by Alan Robinson and Andrew Huet
© Elsevier Science Publishers B.V., 1993

nos casos de **termos de tamanho finito**, podemos usar o algoritmo de Paterson e Wegman (1978) em $O(n)$ encontra o unificador mais geral ou informa que este não existe

nos casos em que se considera **termos infinitos** (mas com uma imposição de um **padrão de regularidade** sobre os termos infinitos) podemos usar o algoritmo de unificação de G. Huet (1976) cuja implementação faz uso da técnica de **union-find**. O algoritmo é relativamente eficiente.

(ver aulas sobre a Análise de Tipos, T e TP onde introduzimos em particular tanto o algoritmo W como o da unificação)

o conceito de base: ver as atribuições como fluxos bi-direcionais: igualdades

as restrições geradas são :

$x = \text{malloc}$	\dashrightarrow	$\&\text{malloc} - i \in \llbracket x \rrbracket$
$x = \&y$	\dashrightarrow	$\&y \in \llbracket x \rrbracket$
$x = y$	\dashrightarrow	$\llbracket y \rrbracket = \llbracket x \rrbracket$
$x = *y$	\dashrightarrow	$\&\alpha \in \llbracket y \rrbracket \implies \llbracket \alpha \rrbracket = \llbracket x \rrbracket$
$*x = y$	\dashrightarrow	$\&\alpha \in \llbracket x \rrbracket \implies \llbracket y \rrbracket = \llbracket \alpha \rrbracket$
$x = \text{null}$	\dashrightarrow	sem restrições

geramos também as restrições adicionais seguintes (restrições de congruência):

$$\&\alpha_1 \&\alpha_2 \in \llbracket t \rrbracket \implies \llbracket \alpha_1 \rrbracket = \llbracket \alpha_2 \rrbracket$$

$$\llbracket t_1 \rrbracket \cap \llbracket t_2 \rrbracket \neq \emptyset \implies \llbracket t_1 \rrbracket \cap \llbracket t_2 \rrbracket$$

o mapa *points-to* é

$$pt(x) \triangleq \{\alpha \mid \&\llbracket \alpha \rrbracket \in \llbracket x \rrbracket\}$$

a procura de solução requer um algoritmo de unificação (como no caso da resolução do problema de tipagem, via por exemplo *union-find*)

restrições geradas (sem as restrições de congruência)

o programa em análise

```
var p,q,x,y,z;
p = malloc;
x = y;
x = z;
*p = z;
p = q;
q = &y;
x = *p;
p = &z;
```

$$\begin{array}{lcl}
 & \& malloc - 1 \in [p] & \\
 & [y] = [x] & \\
 & [z] = [x] & \\
 & \& \alpha \in [p] \implies [z] = [\alpha] & \\
 & [q] = [p] & \\
 & \& y \in [q] & \\
 & \& \alpha \in [p] \implies [\alpha] = [x] & \\
 & \& z \in [p] &
 \end{array}$$

menor solução

$$pt(p) = \{malloc-1, y, z\}$$

$$pt(q) = \{malloc-1, y, z\}$$


menos preciso... mas mais rápido

quais são as restrições de congruência por contemplar no exemplo anterior?

Andersen:



Steensgaard:



```

a1 = &b1;
b1 = &c1;
c1 = &d1;
a2 = &b2;
b2 = &c2;
c2 = &d2;
b1 = &c2;
  
```

para distinguir entre diferentes apontadores para a mesma célula marcamos os constructores de apontadores com $\&_a$ em que a é uma marca fresca
unificar $\&_a\alpha$ com $\&_b\alpha$ não provoca um erro de unificação

actualizamos as restrições geradas :

$$\begin{array}{ll}
 x = \textit{malloc} & \dashrightarrow \llbracket x \rrbracket = \&_v \llbracket \textit{malloc} - i \rrbracket \\
 x = \&y & \dashrightarrow \llbracket x \rrbracket = \&_v \llbracket y \rrbracket \\
 x = y & \dashrightarrow \llbracket x \rrbracket = \&_{v_1} \alpha \wedge \llbracket y \rrbracket = \&_{v_2} \alpha \\
 x = *y & \dashrightarrow \llbracket x \rrbracket = \&_{v_1} \alpha \wedge \llbracket y \rrbracket = \&_{v_2} \&_{v_3} \alpha \\
 *x = y & \dashrightarrow \llbracket x \rrbracket = \&_{v_1} \&_{v_2} \alpha \wedge \&_{v_3} \alpha \\
 x = \textit{null} & \dashrightarrow \text{sem restrições}
 \end{array}$$

juntamos a actualização à restrição de congruência

$$\&_a\alpha_1 = \&_b\alpha_2 \implies \alpha_1 = \alpha_2$$

o mapa *points-to* é agora

$$pt(x) \triangleq \{c \mid \&_a \llbracket c \rrbracket \in \llbracket x \rrbracket\}$$

restrições geradas (sem congruência)

o programa em análise

```

var p,q,x,y,z;
p = malloc;
x = y;
x = z;
*p = z;
p = q;
q = &y;
x = *p;
p = &z;

```

$$\begin{aligned}
\llbracket p \rrbracket &= \&_1 \llbracket \text{malloc}-1 \rrbracket \\
\llbracket x \rrbracket &= \&_2 \alpha_1 \\
\llbracket y \rrbracket &= \&_3 \alpha_1 \\
\llbracket x \rrbracket &= \&_4 \alpha_2 \\
\llbracket z \rrbracket &= \&_5 \alpha_2 \\
\llbracket p \rrbracket &= \&_6 \&_7 \alpha_3 \\
\llbracket z \rrbracket &= \&_8 \alpha_3 \\
\llbracket p \rrbracket &= \&_9 \alpha_4 \\
\llbracket q \rrbracket &= \&_{10} \alpha_4 \\
\llbracket q \rrbracket &= \&_{11} \llbracket y \rrbracket \\
\llbracket x \rrbracket &= \&_{12} \alpha_5 \\
\llbracket p \rrbracket &= \&_{13} \&_{14} \alpha_5 \\
\llbracket p \rrbracket &= \&_{15} \llbracket z \rrbracket
\end{aligned}$$

menor solução - mais uma vez....

$$pt(p) = pt(q) = \{ \text{malloc}-1, y, z \}$$

olhando só para os apontadores e admitindo que o tipo da construção *malloc* é tipo dos apontadores para valores de tipo (variável) α (notação $\&\alpha$)

então as restrições de tipagem das construções que manipulam apontadores (que por comodidade notamos também $\llbracket \cdot \rrbracket$) são

$$\begin{array}{lll}
 x = \text{malloc} & \dashrightarrow & \llbracket x \rrbracket = \&\alpha \\
 x = \&y & \dashrightarrow & \llbracket x \rrbracket = \&\llbracket y \rrbracket \\
 x = y & \dashrightarrow & \llbracket x \rrbracket = \llbracket y \rrbracket \\
 x = *y & \dashrightarrow & \&\llbracket x \rrbracket = \llbracket y \rrbracket \\
 *x = y & \dashrightarrow & \llbracket x \rrbracket = \&\llbracket y \rrbracket \\
 \&\llbracket t_1 \rrbracket = \&\llbracket t_2 \rrbracket & \implies & \llbracket t_1 \rrbracket = \llbracket t_2 \rrbracket (\text{congruência})
 \end{array}$$

assumindo que o programa analisado se submete com sucesso à tipagem, haverá semelhanças entre a solução da fase de tipagem com a solução gerada pelo algoritmo de Steensgaard?

Análise interprocedimental de apontador

se os apontadores de funções são distintos dos apontadores para a *heap*
então **executar primeiro** uma CFA **seguido de** uma análise de Andersen
ou Steengaard

mas se ambos os tipos de apontadores se confundem (é o caso no TIP)
então a CFA e a análise de apontador devem ser **realizadas em
simultâneo!**

exemplo de apontadores mixtos em TIP: $(***x)(1,2,3)$

assumimos que todas as chamadas a funções são da forma

$$x = (y)(a_1, \dots, a_n)$$

assumimos que todas instruções de retorno de funções são da forma

return z;

todos os identificadores de função estão coletados no conjunto *Loc*

mostre como realizar esta normalização de forma sistemática
em particular mostre como esta transformação obriga a uma
(potencialmente volumosa) introdução de variáveis temporárias

como primeira nota, apontemos as semelhanças estruturais que a análise de Andersen tem com a análise de fluxo de controlo no caso da chamada de função $x = (y)(a_1, \dots, a_n)$ e das ocorrências de $f(x_1, \dots, x_n)\{\dots, \text{return } z; \}$ juntamos as restrições

$$\begin{array}{l} f \in \llbracket f \rrbracket \\ f \in \llbracket y \rrbracket \end{array} \implies (\llbracket a_i \rrbracket \subseteq \llbracket x_i \rrbracket \text{ para } i = 1, \dots, n \wedge \llbracket z \rrbracket \subseteq \llbracket x \rrbracket)$$

estas restrições no caso das chamadas tradicionais são semelhantes

o conjunto de restrições pode ser resolvido com a ajuda da *framework* cúbica

no caso da chamada de função $x = (y)(a_1, \dots, a_n)$ e das ocorrências de $f(x_1, \dots, x_n)\{\dots, \text{return } z; \}$
juntamos as restrições

$$\begin{array}{l} f \in \llbracket f \rrbracket \\ f \in \llbracket y \rrbracket \end{array} \implies (\llbracket a_i \rrbracket = \llbracket x_i \rrbracket \text{ para } i = 1, \dots, n \wedge \llbracket z \rrbracket = \llbracket x \rrbracket)$$

estas restrições no caso das chamadas tradicionais são semelhantes

o conjunto de restrições pode ser resolvido aem surpresas com a ajuda da *framework* de unificação

Análise de apontador nulo

pretendemos saber quando, numa dereferência `*p`, `p` pode ser (ou não) nulo


podemos usar a framework monótona, assumindo que um mapa *points-to* foi previamente calculado

porque não tratar `null` como uma localização especial nas análises de tipo Andersen ou Steensgaard

consideremos então aqui uma análise intra-procedimental (i.e. ignoramos as chamadas de funções)

Um reticulado para a análise de apontador Null

definimos o reticulado, designado de *Null*, seguinte




onde *NN* representa “**sem dúvida Não Nulo**”, e \perp representa “não é um apontador”

usamos para cada ponto do programa o reticulado mapa $Cell \rightarrow Null$

trata-se de uma análise em processo

para cada nodo v do CFG, temos a variável $\llbracket v \rrbracket$
esta é uma mapa que atribuí valores abstractos a todas as células (de *Cell*)
no ponto de programa que segue v

$$Join(v) = \sqcup_{w \in predv} \llbracket w \rrbracket$$



Restrições para a análise de apontador nulo

relembramos as operações (os nodos do CFG) que envolvem explicitamente apontadores

$x = \textit{malloc}$

$x = \&y$

$x = y$

$x = *y$

$*x = y$

$x = \textit{null}$

para os outros vértices v do CFG, as restrições são definidas como

$$\llbracket v \rrbracket = \textit{Join}(v)$$

Restrições para a análise de apontador nulo

para uma operação $*x=y$ opera/altera na *heap* (*store operation*), precisamos de modelar as alterações na célula para onde x aponta (qualquer que seja ela)

são candidatas potenciais **várias** células abstractas (as células coletadas em $pt(x)$)

na abstracção em causa, cada célula abstracta da *heap*, `malloc-i` pode descrever **várias** células concretas

esta situação pode ser resolvida com o conceito de **actualização fraca** (*weak update*)

para um nodo v de tipo $*x = y$,

$$\llbracket v \rrbracket = store(Join(v), x, y)$$

onde $store(\sigma, x, y) \triangleq \sigma[\alpha \rightarrow \sigma(\alpha) \sqcup \sigma(y) \mid \forall \alpha \in pt(x)]$

Restrições para a análise de apontador nulo

para uma operação $x = *y$ que carrega valores da *heap*, precisamos de modelar a alteração de uma variável de programa x

a nossa abstracção tem uma **única** célula abstracta para x
com a hipótese de trabalho tomada, que é realizar uma análise intra-procedimental, esta célula representa uma **única** célula concreta

neste contexto podemos nos socorrer da **atualização forte** (*strong update*) para definir as restrições associadas

para um nodo v de tipo $x = *y$,

$$\llbracket v \rrbracket = load(Join(v), x, y)$$

onde $load(\sigma, x, y) \triangleq \sigma[x \rightarrow \sqcup_{\alpha \in pt(y)} \sigma(\alpha)]$

Restrições para a análise de apontador nulo

para os restantes vértices v temos

$$\begin{array}{ll} x = \textit{malloc} & \dashrightarrow \llbracket v \rrbracket = \textit{Join}(v)[x \rightarrow \textit{NN}, \textit{malloc}-i \rightarrow ?] \\ x = \&y & \dashrightarrow \llbracket v \rrbracket = \textit{Join}(v)[x \rightarrow \textit{NN}] \\ x = y & \dashrightarrow \llbracket v \rrbracket = \textit{Join}(v)[x \rightarrow \textit{Join}(v)(y)] \\ x = \textit{null} & \dashrightarrow \llbracket v \rrbracket = \textit{Join}(v)[x \rightarrow ?] \end{array}$$

em cada caso, as atribuições modificam uma variável de programa

podemos então usar as actualizações fortes, como no caso das operações de carregamento

se assumimos que o programa analisado nunca lê de locais memórias não inicializados, podemos remover a substituição $\textit{malloc}-i \rightarrow ?$ do primeiro caso

Explique porque as quatro definições do acetato anteriores são monótonas e correctas

actualização forte: $\sigma[c \rightarrow \text{novo-valor}]$

- possível se se sabe de c que só aponta para uma célula única
- funciona para as atribuições para variáveis locais (na assunção da análise intraprocedimental)

actualização fraca: $\sigma[c \rightarrow \sigma(c) \sqcup \text{novo-valor}]$

- necessária se c refere-se a mais do que uma célula concreta
- má em termos de precisão, perde-se parte do poder do *flow-sensitivity*
- necessária no caso das atribuições na *heap* (a não ser que se estenda a abstracção usada)

a de-referenciação de $*p$ é segura no vértice v se $Join(v)(p) = NN$

a qualidade desta análise depende da qualidade da análise de apontadores subjacentes

```
p = malloc;  
q = &p;  
n = null;  
*q = n;  
*p = n;
```

a análise de Andersen devolve

$$pt(p) = \{malloc-1\}$$

$$pt(q) = \{p\}$$

$$pt(n) = \emptyset$$

$$\begin{aligned}\llbracket p = \text{malloc} \rrbracket &= \perp[p \rightarrow NN, \text{malloc-1} \rightarrow ?] \\ \llbracket q = \&p \rrbracket &= \llbracket p = \text{malloc} \rrbracket[q \rightarrow NN] \\ \llbracket n = \text{null} \rrbracket &= \llbracket q = \&p \rrbracket[n \rightarrow ?] \\ \llbracket *q = n \rrbracket &= \llbracket n = \text{null} \rrbracket[p \rightarrow \llbracket n = \text{null} \rrbracket(p) \sqcup \llbracket n = \text{null} \rrbracket(n)] \\ \llbracket *p = n \rrbracket &= \llbracket * = n \rrbracket[\text{malloc-1} \rightarrow \llbracket *q = n \rrbracket(\text{malloc-1}) \sqcup \llbracket *q = n \rrbracket(n)]\end{aligned}$$

$$\begin{aligned}\llbracket p = \text{malloc} \rrbracket &= [p \rightarrow NN, q \rightarrow \perp, n \rightarrow \perp, \text{malloc-1} \rightarrow ?] \\ \llbracket q = \&p \rrbracket &= [p \rightarrow NN, q \rightarrow NN, n \rightarrow \perp, \text{malloc-1} \rightarrow ?] \\ \llbracket n = \text{null} \rrbracket &= [p \rightarrow NN, q \rightarrow NN, n \rightarrow ?, \text{malloc-1} \rightarrow ?] \\ \llbracket *q = n \rrbracket &= [p \rightarrow ?, q \rightarrow NN, n \rightarrow ?, \text{malloc-1} \rightarrow ?] \\ \llbracket *p = n \rrbracket &= [p \rightarrow ?, q \rightarrow NN, n \rightarrow ?, \text{malloc-1} \rightarrow ?]\end{aligned}$$

no ponto do programa antes de $*q = n$, a análise sabe que q é definitivamente não nulo

antes de $*p = n$, o apontador p pode ser nulo


devido as actualizações fracas realizadas em todas as operações de arquivo (*store*) na *heap*, a precisão é má para as localizações *malloc- i*

Análise de forma

A *heap* como estrutura de primeira classe nas análises

a *heap* tem uma influência notória no comportamento de programas com apontadores
em particular a sua segmentação e a evolução desta segmentação no curso da execução é relevante
por exemplo saber decidir se apontadores evoluem em zonas distintas da memória (e.g. *heap*) tem impacto na análise comportamental de um programa

consideremos por exemplo esta estrutura não trivial de uma *heap*



é relevante poder decidir **as zonas de disjunção** da *heap*

- x e y não são disjuntos
- y e z são disjuntos

são grafos que descrevem possíveis *heap*

- vértices são células abstractas
- arestas são possíveis apontadores entre células

o reticulado de grafos de forma é

$$L \triangleq (\mathcal{P}(\text{Cell} \times \text{Cell}), \subseteq)$$

cada vértice v do CFG introduzimos uma variável de restrição $\llbracket v \rrbracket$ que descreve o estado **após** v

por enquanto, olhemos para uma análise intra-procedimental (i.e. ignoramos as chamadas de função)

tendo em conta que para um vértice v ,

$$Join(v) = \sqcup_{w \in pred(v)} \llbracket w \rrbracket$$

as restrições para operações que lidam com apontadores são

$$\begin{array}{ll}
 x = \textit{malloc} & \dashrightarrow \llbracket v \rrbracket = Join(v) \downarrow_x \cup \{(x, \textit{malloc}-i)\} \\
 x = \&y & \dashrightarrow \llbracket v \rrbracket = Join(v) \downarrow_x \cup \{(x, y)\} \\
 x = y & \dashrightarrow \llbracket v \rrbracket = \textit{assign}(Join(v), x, y) \\
 x = *y & \dashrightarrow \llbracket v \rrbracket = \textit{load}(Join(v), x, y) \\
 *x = y & \dashrightarrow \llbracket v \rrbracket = \textit{store}(Join(v), x, y) \\
 x = \textit{null} & \dashrightarrow \llbracket v \rrbracket = Join(v) \downarrow_x
 \end{array}$$

para todos os outros vértices v do CFG, $\llbracket v \rrbracket = Join(v)$

onde

$$\begin{aligned}\sigma \downarrow_x &= \{(s, t) \in \sigma \mid s \neq x\} \\ \text{assign}(\sigma, x, y) &= \sigma \downarrow_x \cup \{(x, t) \mid (y, t) \in \sigma\} \\ \text{load}(\sigma, x, y) &= \sigma \downarrow_x \cup \{(x, t) \mid (y, s) \in \sigma, (s, t) \in \sigma\} \\ \text{store}(\sigma, x, y) &= \sigma \cup \{(s, t) \mid (x, s) \in \sigma, (y, t) \in \sigma\}\end{aligned}$$

de notar que a operação *store* utiliza **actualização fraca**

```
var x,y,n,p,q;  
x = malloc;  
y = malloc;  
*x = null;  
*y = y;  
n = input;  
while (n>0) {  
    p = malloc;  
    q = malloc;  
    *p = x; *q = y;  
    x = p; y = q;  
    n = n-1;  
}
```

com base na análise de forma, obtemos o grafo seguinte após o ciclo



concluimos que x e y serão sempre distintos

De mapas *point-to* para grafos de forma

a análise de forma é também uma análise *points-to* sensível ao fluxo visto que

$$pt(x) = \{t \mid (x, t) \in \llbracket v \rrbracket\}$$

é um mapa *points-to*

mais custos mais também mais preciso:

```
x=&y;  
x=&z;  
// <---- aqui
```

no ponto assinalado

- análise de Andersen: $pt(x) = \{y, z\}$
- análise de forma : $pt(x) = \{z\}$

podem ser combinadas, usando a análise de Andersen para a construção do CFG e utilizando a análise de forma para melhorar a análise de apontador nulo


a análise de forma está a falhar na recolha de informação: o vértice *malloc*—2 forma sistematicamente um ciclo para ele próprio no exemplo

para lidar com este tipo de fenómenos, temos de usar um reticulado mais informativo

$$\mathcal{P}(\text{Cell} \times \text{Cell}) \times (\text{Cell} \rightarrow \text{Count})$$

onde se guarda para cada célula o registo de quantas células concretas cada célula abstracta descreve

esta informação permite **actualizações fortes** nas células que descrevem **exactamente** uma célula concreta



defina o conjunto novo de restrições associado a este reticulado e a esta análise de forma para cada nodo ($x = \textit{malloc}$, $*x = y$, etc.) do CFG

com o exemplo anterior e após o ciclo obtemos então o grafo de forma seguinte



já se consegue neste caso perceber que o vértice *malloc-2* forma sistematicamente um ciclo para ele próprio

para estender a análise no contexto interprocedimental é necessário considerar

- passagem de parâmetros
- actualização fraca de células localizadas na pilha (**frame/operand stack**)
- o fenómeno de fuga de células da pilha (**escape of stack cells**)

para lidar com o referido fenómeno podemos proceder da seguinte forma

realizar uma análise de forma

olhar para a expressão de retorno

avaliar no grafo de forma a acessibilidade
(*reachability*) dos argumentos ou variáveis
definidas na função em si

se nenhuma desses está acessível , então não há
fuga de células de pilha

```
baz() {  
    var x;  
    return &x;  
}  
  
main() {  
    var p;  
    p=baz();  
    *p=1;  
    return *p;  
}
```

As aulas de Análise Estáticas de Programas desta UC baseam-se em duas fontes essenciais:

- Anders Møller and Michael I. Schwartzbach. Static Program Analysis (acetatos e sebenta).
- Flemming Nielson, Hanne R. Nielson, and Chris L. Hankin. Principles of Program Analysis (um *must read!*).

