Analiza fluxului de date

31 octombrie 2013

Analiză statică: definiție

O analiză a *codului sursă* (fără a executa programul), cu scopul de a determina *proprietăți* ale programului sursă.

(in principal corectitudinea, dar și performanță, etc.)

Complementare analizelor *dinamice* (prin rularea codului)

Exemple de proprietăți:

- variabile neinițializate (particular: pointeri nuli)
- atribuiri nefolosite
- vulnerabilități de cod (excepții, depășiri de indici), etc.

De obicei, analizele statice sunt legate de *semantica* programului uneori: și analize limitate la *structura* (sintactică) a codului

Istoric:

(sub)domeniu legat de *compilatoare*: în special pentru optimizare

mai recent: în *proiectarea limbajelor*; pentru *detectarea de erori*

Structura generală a unei analize

O analiză statică stabilește o afirmație (proprietate, rezultat)
valabilă pentru *toate* căile de executie

dar: numărul de căi de execuție într-un program e potențial infinit
nu putem scrie un algoritm care să parcurgă toate căile
$\Rightarrow$ trebuie algoritmi cu altă structură (și uneori aproximări)

Exemplu / analogie: drumuri minime într-un graf.
Pt. drumul minim între v_0 și v_1 putem încerca:

$v_0 v_1$,
$v_0 v_2 v_1$, ... $v_0 v_{n-1} v_1$,
$v_0 v_2 v_3 v_1$, $v_0 v_2 v_4 v_1$, ... $v_0 v_{n-2} v_{n-1} v_1$,
$v_0 v_2 v_3 v_4 v_1$, ...

Analogie: drumuri minime într-un graf

```
for (k = 0; k < n; ++k)
  for (i = 0; i < n; ++i)
    for (j = 0; j < n; ++j)
      if (d[i][k] + d[k][j] < d[i][j])
        d[i][j] = d[i][k] + d[k][j]
```

sau, generic:
calculează o valoare (aici: lungimea unui drum)
cât timp există o schimbare (punct intermediar cu drum mai scurt)
$\Rightarrow$ ciclul se oprește când o iterație *nu mai produce vreo schimbare*

Analiza fluxului de date

Tehnici cu originea în domeniul compilatoarelor
folosite pentru *generarea* de cod (alocarea de regiștri)
și *optimizarea* de cod (propagarea constantelor, factorizarea expresiilor comune, detectarea variabilelor nefolosite, etc.)

Aceleași tehnici pot fi aplicate și la probleme de *analiză* de cod (într-un cadru foarte general)

Ideea de bază:
construirea grafului de flux de control al programului
urmărirea modului în care proprietățile de interes se modifică pe parcursul programului (la traversarea nodurilor / muchiilor grafului)

Graful de flux de control al programului

Reprezentare în care:
- nodurile sunt instrucțiuni
- muchiile indică secvențierea instrucțiunilor (inclusiv salturi)

$\Rightarrow$ putem avea: noduri cu:
- un singur succesor (ex. atribuiri),
- mai mulți succesori (instrucțiuni de ramificație)
- mai mulți predecesori (reunirea după ramificație)

Obs.: Alternativ, dar mai puțin folosit:
- nodurile sunt puncte din program (valori pentru PC)
- muchiile sunt instrucțiuni cu efectele lor

Notații

$G = (N, E)$: graful de flux de control (N : noduri; E : muchii)

s : o instrucțiune de program (nod în graful de flux de control)

entry, *exit* : punctele de intrare și de ieșire din program

$in(s)$: mulțimea muchiilor care au s ca destinație

$out(s)$: mulțimea muchiilor care au s ca sursă

$src(e)$, $dest(e)$: instrucțiunea sursă și destinație a muchiei e

$pred(s)$: mulțimea predecesorilor instrucțiunii s

$succ(s)$: mulțimea predecesorilor instrucțiunii s

Scriem *ecuații de flux de date*:

descriu cum se modifică valorile analizate (dataflow facts) de la o instrucțiune la alta.

Avem nevoie de valoarea analizată

la intrarea instrucțiunii s (indice $_{in}$)

și la ieșirea instrucțiunii (indice $_{out}$)

Exemplu: Reaching definitions

Care sunt toate *atribuirile* (definițiile) *care pot atinge punctul curent* (înainte ca valorile atribuite să fie suprascrise) ?

Elementele de interes sunt perechi: (variabilă, linie de definiție).
Pentru fiecare instrucțiune (identificată cu eticheta ei l) ne interesează valoarea dinainte $RD_{in}(s)$ și de după $RD_{out}(s)$

Nodul inițial din graf nu e atins de nici o definiție:

$$RD_{out}(entry) = \{(v, ?) \mid v \in V\}$$

O *atribuire* $l : v \leftarrow e$

șterge toate definițiile anterioare (pt. variabila v, nu alte variabile) și introduce ca definiție instrucțiunea curentă

$$RD_{out}(l : v \leftarrow e) = (RD_{in}(s) \setminus \{(v, s')\}) \cup \{(v, l)\}$$

Definițiile de la *intrarea* unei instrucțiuni
sunt *reuniunea* definițiilor de la *ieșirea* instrucțiunilor precedente:

$$RD_{in}(s) = \bigcup_{s' \in pred(s)} RD_{out}(s')$$

Exemplu: Live variables analysis

În fiecare punct de program, ce variabile vor avea valoarea folosită pe cel puțin una din căile posibile din acel punct ?
(analiză utilă în compilatoare pentru alocarea regiștrilor)

Funcția de transfer: $LV_{in}(s) = (LV_{out}(s) \setminus write(s)) \cup read(s)$
O variabilă e *live* înainte de s
dacă e citită de s
sau e*live* după s fără a fi scrisă de s $\Rightarrow$ sensul analizei e *înapoi*

Operația de combinare (meet):

$$LV_{out}(s) = \begin{cases} \emptyset & \text{dacă } succ(s) = \emptyset \\ \bigcup_{s' \in succ(s)} LV_{in}(s') & \text{altfel} \end{cases}$$

$\Rightarrow$ combinarea făcută prin uniune (*may*, pe cel puțin o cale)
Calculul: algoritm de tip *worklist* care face modificări pornind de la valorile inițiale până nu mai apar schimbări $\Rightarrow$ se atinge un *punct fix*

Exemplu: Available expressions

În fiecare punct de program, care sunt expresiile a căror valoare a fost calculată anterior, fără să se modificat, pe toate căile spre acel punct?
(dacă valoarea se ține minte într-un registru, nu trebuie recalculată)
Funcția de transfer: $AE_{out}(s) = (AE_{in}(s) \setminus \{e \mid V(e) \cap write(s) \neq \emptyset\})$
$\cup \{e \in Subexp(s) \mid V(e) \cap write(s) = \emptyset\}$
(expresiile de la intrarea în s care nu au variabile modificate de s,
și orice expresii calculate în s fără a li se modifica variabilele)

Operația de combinare (meet):

$$AE_{in}(s) = \begin{cases} \emptyset & \text{dacă } pred(s) = \emptyset \\ \bigcap_{s' \in pred(s)} AE_{out}(s') & \text{altfel} \end{cases}$$

$\Rightarrow$ combinarea e făcută prin intersecție (*must*, pe toate căile);
analiza e *înainte*

Exemplu: Very busy expressions

Care sunt expresiile care trebuie evaluate pe orice cale din punctul curent înainte ca valoarea vreunei variabile din ele să se modifice ?
$\Rightarrow$ evaluarea se poate muta în punctul curent, înainte de ramificații
– o analiză înapoi, și de tip universal (*must*)

$$VBE_{in}(s) = (VBE_{out}(s) \setminus \{e \mid V(e) \cap write(s) \neq \emptyset\}) \cup Subexp(s)$$

$$VBE_{out}(s) = \begin{cases} \emptyset & \text{dacă } succ(s) = \emptyset \\ \bigcap_{s' \in succ(s)} VBE_{in}(s') & \text{altfel} \end{cases}$$

Proprietăți analizate (dataflow facts)

Concret: analizăm diverse proprietăți, de ex.
– valoarea unei variabile într-un punct de program
– sau *intervalul* de valori pentru o variabilă
– sau mulțimi de variabile (live), expresii (available, very busy), definiții posibile pentru o valoare (reaching definitions), etc.

Abstract: o mulțime D de valori pentru o proprietate (*dataflow facts*)
Restricție: D e o mulțime *finită*

Latice

O *latice* e o mulțime *parțial ordonată*, în care orice două elemente au un *minorant* și un *majorant*.
(elemente mai mici, respectiv mai mari în ordine decăt cele două). Ex: mulțimea părților unei mulțimi (intersecție, reuniune)
Ex: mulțimea divizorilor unui număr (c.m.m.d.c, c.m.m.m.c)

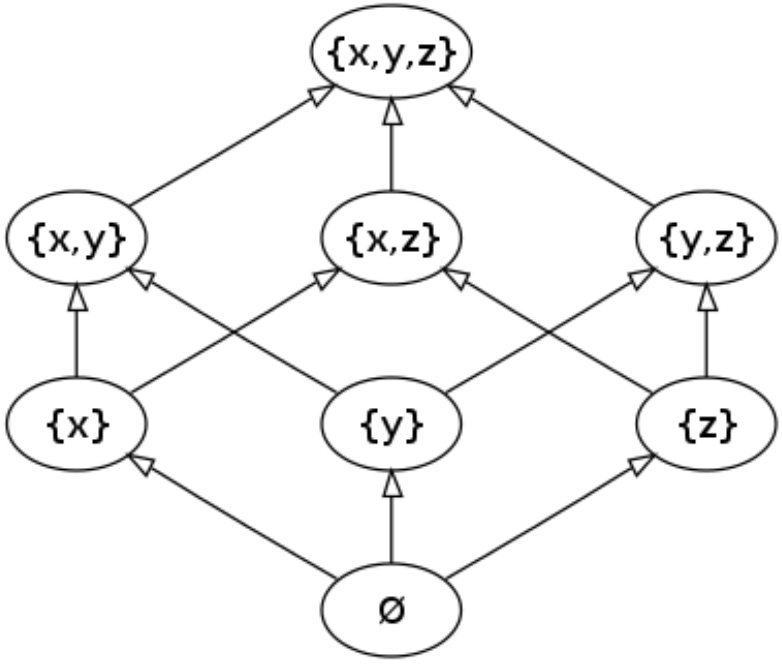

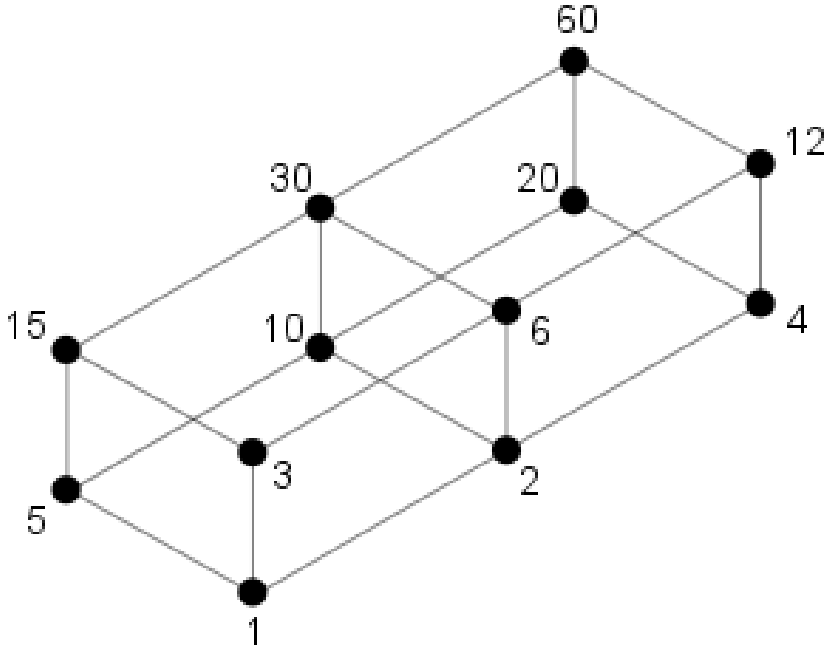

Imagine: http://en.wikipedia.org/wiki/File:Hasse_diagram_of_powerset_of_3.svg

http://en.wikipedia.org/wiki/File:Lattice_of_the_divisibility_of_60.svg

Funcții de transfer

Concret: instrucțiunile determină modificări ale stării programului. Valoarea unei variabile după o instrucțiune e o funcție a valorii de la începutul instrucțiunii.

Abstract: Fiecare instrucțiune s are asociată o funcție de transfer $F(s) : L \to L$ care determină modul în care valoarea proprietății la începutul instrucțiunii e modificată de instrucțiune:
$Prop_{out}(s) = F(s)(Prop_{in}(s))$ (pentru analize înainte),
sau invers (pentru analize înapoi)

Restricție: punem condiția ca funcțiile de transfer să fie *monotone*:

$$x \sqsubseteq y \Rightarrow f(x) \sqsubseteq f(y)$$

(dacă știm mai multe despre argument, atunci și despre rezultat)

Caz particular: *bitvector frameworks*: laticea e o mulțime de părți $\mathcal{P}(D)$, funcții de transfer monotone și de forma:

$$F(s)(v) = (v \setminus kill(s)) \sqcup gen(s)$$

(v = dataflow fact, $gen/kill(s)$ = informația generată/eliminată în s)

Ecuații de flux de date

Exemplu: pentru analize înainte:

$$Prop_{out}(s) = F(s)(Prop_{in}(s))$$
$$Prop_{in}(s) = \bigsqcap_{s' \in pred(s)} Prop_{out}(s')$$

unde prin $\bigsqcap$ am reprezentat efectul combinării informațiilor (*meet*) pe mai multe căi (ar putea fi $\cap$ sau $\cup$)

Inițial, e cunoscută valoarea $Prop_{out}(entry)$.

Pentru analize înapoi, se schimbă rolul între *in* și *out*, și e cunoscută valoarea lui $Prop_{in}(exit)$.

Soluția: Algoritm de tip *worklist*

Pentru calculul soluției la sistemul de ecuații de mai sus:
algoritmi iterativ care propagă modificările în sensul analizei

foreach $s \in N$ **do** $Prop_{in}(s) = \top$ /* no info */
$Prop_{in}(entry) = init$ /* in functie de analiza */
$W = \{entry\}$
while $W \neq \emptyset$
    choose $s \in W$
    $W = W \setminus \{s\}$
    $Prop_{in}(s) = \bigsqcap_{s' \in pred(s)} Prop_{out}(s')$
    $Prop_{out}(s) = F(s)(Prop_{in}(s))$
    if change **then**
        forall $s' \in succ(s)$ **do** $W = W \cup \{s'\}$

Terminare: condiția de punct fix

Terminarea analizei e garantată dacă funcția de transfer e monotonă: $x \sqsubseteq y \Rightarrow f(x) \sqsubseteq f(y)$, ceea ce implică faptul că proprietățile calculate se modifică în mod monoton.

Def: *Punct fix* pentru o funcție f: o valoare x pt. care $f(x) = x$
Teorema lui Tarski garantează că o funcție monotonă pe o latice completă are un punct fix minimal și un punct fix maximal.

Algoritmul worklist calculează punctul fix minimal dat fiind sistemul de funcții de transfer.

Meet over all paths

Dorim să calculăm efectul combinat al instrucțiunilor programului:
pentru $p = s_1 s_2 \ldots s_n$ șir de instrucțiuni definim

$$F(p) = F(s_n) \circ \ldots \circ F(s_2) \circ F(s_1)$$

și dorim să calculăm:

$$\bigsqcap_{p \in Path(Prog)} F_p(entry)$$

Dar algoritmul iterativ combină efectele la fiecare punct de întâlnire înainte de a calcula mai departe. Funcțiile f fiind monotone, avem:

$$f(x \sqcup y) \sqsupseteq f(x) \sqcup f(y)$$

deci analiza *pierde din precizie*
Pentru funcțiile de transfer *distributive* avem chiar:
$f(x) \cup f(y) = f(x \cup y)$

Se demonstrează că în acest caz algoritmul iterativ (care generează o soluție de punct fix) e echivalent cu calculul soluției prin combinarea valorilor pe toate căile posibile (*meet over all paths*).
$\Rightarrow$ combinarea diverselor căi de execuție nu pierde informație

Cele 4 exemple date (live variables, etc.) sunt distributive.

Clasificare a analizelor

– înainte sau înapoi
– must sau may
– dependente sau independente de fluxul de control (flow (in)sensitive):
Trebuie luată în considerare ordinea instrucțiunilor în program
– nu: ce variabile sunt folosite/modificate, funcții apelate, etc.
– da: proprietăți legate de valorile calculate efective de program
– dependente sau independente de context
în cazul programelor ce conțin proceduri: e specializată analiza fiecărei proceduri în funcție de locul de apel, sau se poate face un sumar (o analiză comună) ?
– dependente sau nu de cale (*path*-(in)sensitive)
(ține cont de corelările pe căile individuale de execuție ?)