

## Analiza fluxului de date

4 mai 2004

- O sistematizare a analizelor de flux de date
- Analiza interprocedurale
- Aplicație: property simulation

### 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 multimi 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*

## Mulțimi parțial ordonate

**Concret:**

- am asociat cu punctele de program *mulțimi* de valori pentru proprietatea analizată
- am recalculate iterativ mulțimile respective, prin operații de *reuniune* sau *intersectie*; obținând tot mai multe (sau mai puține) valori

Care sunt premisele esențiale pentru a efectua calculele în acest fel ?

**Abstract:** O *multime parțial ordonată*  $(L, \sqsubseteq)$  e o mulțime echipată cu o *relație de ordonare parțială*  $\sqsubseteq \subseteq L \times L$ , adică o relație:

- reflexivă,  $x \sqsubseteq x$  pentru orice  $x \in L$
- tranzitivă,  $x \sqsubseteq y \wedge y \sqsubseteq z \Rightarrow x \sqsubseteq z$ , pentru orice  $x, y, z \in L$
- antisimetrică:  $x \sqsubseteq y \wedge y \sqsubseteq x \Rightarrow x = y$ , pentru orice  $x, y \in L$

Exemplu: mulțimea părților  $(\mathcal{P}(D), \subseteq)$  sau  $(\mathcal{P}(D), \supseteq)$

## Latici (cont.)

Operațiile  $\sqcap$  (meet) și  $\sqcup$  (join) au proprietăți:

- sunt comutative
- sunt asociative
- $x \sqcap \perp = \perp$  și  $x \sqcup \top = \top$ , pentru orice  $x$ .

**Latică distributivă:** în care operatorii  $\sqcap$  și  $\sqcup$  sunt reciproc distributivi:

$$\begin{aligned} x \sqcap (y \sqcup z) &= (x \sqcap y) \sqcup (x \sqcap z) \\ x \sqcup (y \sqcap z) &= (x \sqcup y) \sqcap (x \sqcup z) \end{aligned}$$

## Functii 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  $F(s) : L \rightarrow L$  care determină modul în care valoarea proprietății la începutul instrucțiunii e modificată de instrucțiune:

$$Prop_{out}(s) = F(s)(Prop_{in}(s)) \quad (\text{pentru analize înainte}),$$

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 stim mai multe despre argument, atunci și despre rezultat)

Caz particular: *bitvector frameworks*: latica 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  $s$ )

## Ecuări de flux de date

Exemplu: pentru analize înainte:

$$Prop_{out}(s) = F(s)(Prop_{in}(s))$$

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

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

Initial, 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  $Prop_{in}(s) = T$  /* no info */
 $Prop_{in}(entry) = init$  /* in functie de analiza */
 $W = \{entry\}$ 
while  $W \neq \emptyset$ 
    choose  $s \in W$ 
     $W = W \setminus \{s\}$ 
     $Prop_{in}(s) = \prod_{s' \in pred(s)} Prop_{out}(s')$ 
     $Prop_{out}(s) = F(s)(Prop_{in}(s))$ 
    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 latică 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  $p = s_1 s_2 \dots s_n$  sir de instrucții definim

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

și dorim să calculăm:

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

Dar algoritmul iterativ combină efectele la fiecare punct de înțălnire 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*).

⇒ 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 contin proceduri: e specializată analiza fiecărei proceduri în funcție de locul de apel, sau se poate face un sumar (o analiză comună) ?

## Analize interprocedurale

Modelarea programelor cu proceduri: în graful de flux de control, un - muchie de la locul de apel la începutul procedurii  
- muchie de la sfârșitul procedurii la instrucțiunea de după apel

În felul acesta, se obțin toate căile, dar și căi nefezabile

⇒ se restrâng analiza asupra căilor *realizabile*, în care apelurile și reîntoarcerile din funcții sunt împerecheate corect

## Property simulation

---

[Das, Lerner, Seigle '02 - Microsoft + U. Washington]

- o analiză statică (*property simulation*) scalabilă la  $n \cdot 100$  kloc
- exemplu: absența de erori în > 600 apeluri de sistem pentru 15 pointeri de fișiere în codul gcc (140 kloc)
- prin analiză hibridă între o analiză standard de flux de date (imprecisă) și analiză dependentă de cale (path-sensitive, prea costisitoare)
- păstrând corelarea dintre starea proprietății analizate (ex. `uninit`, `open`, `closed` pentru fișier) și variabilele relevante din program

```

if (dump)
    f = fopen(dumpFil, "w");
if (p) x = 0; else x = 1;
if (dump) fclose(f);
```

## Transformarea în problemă de parcurgere de grafuri

---

[Reps, Horwitz, Sagiv '95]

- pentru un subset de probleme de analiză de flux de date (interprocedural, finite, distributive subset problem)