



Programmide teisendamine

Osaline väärtustamine

Jaak Pruulmann

jjpp@meso.ee



Mis v rk on?

- Osaline v rtustamine e. spetsialiseerimine
 $f(x, y) = x^y, y = 5 \Rightarrow f_5(x) = x^5$
- Rakendatakse programmitekstidele
- Eesm rk: automaatselt rakendatavus
- Eesm rk: programmide genereerimine
- Kleene'i s-m-n teoreem

Näide: astendamine

- Algne programm $p =$


$$\begin{aligned} f(n, x) &= \text{if } n = 0 \text{ then } 1 \\ &\text{else if even}(n) \text{ then } f(n/2, x) \wedge 2 \\ &\text{else } x * f(n-1, x) \end{aligned}$$

- Programm p pärast spetsialiseerimist staatilise sisendiga $n = 5$, $p_5 =$

$$f_5(x) = x * ((x \wedge 2) \wedge 2)$$

Skeem

- Olgu meil programm $p(in1, in2)$.



Kontrolliks: $[[p]][in1, in2] = [[p_{in1}]]in2$

Tähistusi

- Olgu D kõigi väärtuste (sh programmitekstid) hulk.
- Kasutame keeli L (implementeerimiskeel), S (lähtetekstide keel) ja T (sihtkeel).
- Programmi tähendus $[[_]]_L$ on funktsioon $D^* \rightarrow D$.
- Olgu meil programm p keeles L , siis $[[p]]_L$ on selle tähendus.
- $out = [[p]]_L[in_1, in_2, \dots, in_n]$ tagastab p väljundi sisenditel in_1 kuni in_n või on defineerimata, kui p ei lõpeta.

Veel tähistusi

Kui in_1 on programmi kõik staatilised sisendid ja in_2 programmi kõik dünaamilised sisendid, siis

- $out = [[p]][in_1, in_2]$ on üheastmeline arvutus ja
- $p_{in_1} = [[mix]][p, in_1], out = [[p_{in_1}]]in_2$ on kaheastmeline arvutus, millest saame mix 'i definitsiooni:
- $[[p]][in_1, in_2] = [[[[mix]][p, in_1]]]in_2$ (kui üks pool on defineeritud, on ka teine defineeritud ning omab sama väärtust)

Milleks meile osaline väärtustamine?

- Harva muutuvad andmed
- Sageli: $t_{mix}(p, in1) + t_{p_{in1}}(in2) < t_p(in1, in2)$
- Efektiivsus vs üldisus
- Muud keerulised ülesanded: raytracing, andmebaasipäringud, teadusarvutused, pattern-matching

Kuidas me seda teeme?

- Automaatselt: *sümbolarvutus, avamine, programmipunktide spetsialiseerimine*
- Offline:
 - (0) annoteeri programmi tekst (*binding-time analysis*; märgitakse dynaamilist sisendit kasutavad osad)
 - (1) arvuta kõik märkimata (staatiliselt) avaldised
 - (2) ava kõik märkimata funktsiooniväljakutsed
 - (3) genereeri jääkkood (*residual code*) kõigile märgitud avaldistele
 - (4) genereeri jääkväljakutsed kõigile märgitud funktsioonide väljakutsetele

Kuidas me seda teeme?

• Online:

- arvutab asju esimesel võimalusel, kasutades ainult ja kogu kättesaadavat infot
- on üldjuhul parem, eriti struktuursete, osaliselt staatiliste andmete korral
- väärtustaja peatumine pole päris garanteeritud jms probleemid

binding-time analysis

- annotatsioonide aluseks on teadmine selle kohta, millised sisendid on programmi spetsialiseerimisel teada.
- operatsioonid märgitakse kas eemaldatavaks või jäävaks (*eliminable, residual*)
- nõutakse, et eemaldatuks märgitud operatsioon oleks eemaldatav suvalise staatilise sisendi korral (kongruentsus, automaatselt saavutatav)
- sõltumata sisendist ei tohi spetsialiseerija saada produtseerida lõpmatult paljusid funktsioone ega lõpmatult suuri avaldisi (peatumine)

Kompilaatorid, interpretaatorid 1

- Enamus arvutusi on tehtavad kas ühe või mitme sammuga, kasutades programmide genereerimist.
- Levinud näited mitme sammuga arvutamisest on kompilaatorid ja parserigeneraatorid.
- Võrdlus: interpretaatorid on väiksemad, lihtsamad, aeglasemad.

Kompilaatorid, interpretaatorid 2

- Interpretaator:

$$\begin{aligned} out &= [[source]]_S[in_1, in_2, \dots, in_n] \\ &= [[int]]_L[source, in_1, in_2, \dots, in_n] \end{aligned}$$

- S'i interpretaator keeles L:

$$[[source]]_S d = [[int]]_L[source, d]$$

- Kompilaator:

$$\begin{aligned} target &= [[compiler]]_L source \\ output &= [[source]]_S[in_1, in_2, \dots, in_n] \\ &= [[target]]_T[in_1, in_2, \dots, in_n] \end{aligned}$$

- S'ist T'sse kompileeriv kompilaator keeles L:

$$[[source]]_S d = [[[[compiler]]_L source]]_T d$$

Kompilaatorid, interpretaatorid 3

- Spetsialiseeritud interpretaator = kompilaator:
 $target = [[mix]][int, source]$
- *mix* ei ole kompilaator!
- Kaotame interpreteerimis-*overhead*'i
- Väljundprogramm on alati korrektne (interpretaatori suhtes)
- Sihtkeel ei tarvitse kõige mõistlikum olla?
- Uusi andmetüüpe vms ei leiutata, teisendused on üldised ja automaatsed – käsitsi kodeeritud kompilaator on võibolla efektiivsem.

Interpreteerimiskulud

- üldiselt: $a_p * t_p(d) \leq t_{int}(p, d)$, kus a_p ei sõltu sisendist d kuid võib sõltuda programmist p .
- eksperimentaalselt kipub a_p olema 10
- *sint* – self-interpreter:
$$[[p]]d = [[sint]][p, d] = [[[[mix]][sint, p]]]d$$
$$p' = [[mix]][sint, p] = p$$

Generaatorite generaatorid

- Kui spetsialiseerija on sobivas keeles, saame ka seda spetsialiseerida – kiiremaks muuta.
- Praktikas ei kasutata üldiseid programme – spetsifikatsioonide täitjaid, sest need oleks liiga aeglased
- Samas on spetsifikatsioonid loetavamad ja kergemini muudetavad

Futamura projektsioonid

1. kompilaator:

$$\begin{aligned} out &= [[source]]input = [[int]][source, input] \\ &= [[[[mix]] [int, source]]]input = [[target]]input \end{aligned}$$

2. kompilaatorigeneraator:

$$\begin{aligned} compiler &= [[mix]][mix, int] \\ target &= [[mix]][int, source] = \\ &= [[[[mix]][mix, int]]]source \\ &= [[compiler]]source \end{aligned}$$

Futamura projektsioonid

3. kompilaatorigeneraatori generaator:

$$\begin{aligned} cogen &= [[mix]][mix, mix] \\ [[p]][in1, in2] &= \\ [[[[mix]][p, in1]] in2 &= \\ [[[[[[mix]][mix, p]] in1]] in2 &= \\ [[[[[[[[mix]][mix, mix]] p]] in1]] in2 &= \\ [[[[[[cogen]] p]] in1]] in2 \end{aligned}$$

Automaatne genereerimine

compiler = $[[cogen]]int$ – L'is kirjutatud L'st L'i teisendaja.

- instrumenteerimine (debug-laused vms)
- CPS
- laisast virgaks
- sabarekursiooni kasutavaks

Veel

- semantikapõhised kompilaatorid
- osaline väärtustamine ei ravi kõiki hädasid
- üldised programmid
- pole nii automaatne, kui võiks olla