

Komplexitätsanalyse mit Typen

Vor-/Nachwort

- ▶ Dieser Vortrag war an Schüler gerichtet, die sich für das Informatikstudium interessieren, und sollte einen groben Einblick in meine Forschungsarbeit geben.
- ▶ Folien 27–42 “Warteschlange” waren durch eine Demonstration begleitet, in der die Speicherungen von Objekten in Listen durch bunte Bauklötze in durchsichtigen, gestapelten Plastikbechern visualisiert wurde. Die Inferenz eines Systems linearer Gleichungen wurde mithilfe von farbigen Schüsseln (für Variablen) und Münzen darin (Wert der Variablen) dargestellt.
- ▶ Der gezeigte Programmcode ist in der funktionalen und frei verfügbaren Sprache **Haskell** verfasst, da dieser ohne besondere Vorkenntnisse leicht verständlich ist. Näheres siehe <http://www.Haskell.org>.
- ▶ Am Ende des Vortrages wurde die Automatisierte Amortisierte Analyse des Warteschlangen Programm live mit der Software des EmBounded Projektes demonstriert und im Detail betrachtet.

<http://www.embounded.org/software/cost/cost.cgi> EmBounded Software
<http://kashmir.dcc.fc.up.pt/aalazy.cgi> Neueste Analyse
<http://raml.tcs.ifi.lmu.de/prototype> Polynomielle Schranken

Komplexitätsanalyse mit Typen

Dr Steffen Jost

München

26. März 2013



Was kommt heraus?

$2 + 3 =$

`"Wahr oder Falsch" ≡ True ∨ False =`

`0 == 1 ∧ 4 + 5 == 9 =`

`"Hello" ++ "World!" =`

`3 * "Hello" =`

`26 * 32013 =`

`if 0 == 1 then 1 + 2 else 3 * 4 =`

`if 42 then "Richtig" else 56 =`

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$$2 + 3 = 5$$

“Wahr oder Falsch” \equiv True \vee False =

$$0 == 1 \wedge 4 + 5 == 9 =$$

“Hello” ++ “World!” =

$$3 * \text{“Hello”} =$$

$$26 * 3^{2013} =$$

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then “Richtig” else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$$2 + 3 = 5$$

“Wahr oder Falsch” \equiv True \vee False = True

$$0 == 1 \wedge 4 + 5 == 9 =$$

“Hello” ++ “World!” =

$$3 * \text{“Hello”} =$$

$$26 * 3^{2013} =$$

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then “Richtig” else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$$2 + 3 = 5$$

“Wahr oder Falsch” \equiv True \vee False = True

$$(0 == 1) \wedge ((4 + 5) == 9) = \text{False}$$

“Hello” ++ “World!” =

$$3 * \text{“Hello”} =$$

$$26 * 3^{2013} =$$

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then “Richtig” else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$$2 + 3 = 5$$

“Wahr oder Falsch” \equiv True \vee False = True

$$(0 == 1) \wedge ((4 + 5) == 9) = \text{False}$$

“Hello” ++ “World!” = “Hello World!”

$$3 * \text{“Hello”} =$$

$$26 * 3^{2013} =$$

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then “Richtig” else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$$2 + 3 = 5$$

“Wahr oder Falsch” \equiv True \vee False = True

$$(0 == 1) \wedge ((4 + 5) == 9) = \text{False}$$

“Hello” ++ “World!” = “Hello World!”

$$3 * \text{“Hello”} = ?$$

$$26 * 3^{2013} = ?$$

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then “Richtig” else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$$2 + 3 = 5$$

“Wahr oder Falsch” \equiv True \vee False = True

$$(0 == 1) \wedge ((4 + 5) == 9) = \text{False}$$

“Hello” ++ “World!” = “Hello World!”

$$3 * \text{“Hello”} = ?$$



$$26 * 3^{2013} = 7245 \dots 2398 \quad :: \text{Int}$$

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then “Richtig” else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$ *:: Int*

"Wahr oder Falsch" \equiv True \vee False = True

$(0 == 1) \wedge ((4 + 5) == 9) =$ False

"Hello" ++ "World!" = "Hello World!"

$3 * \text{"Hello"} = ?$ *⚡*

$26 * 3^{2013} = 7245 \dots 2398$ *:: Int*

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then "Richtig" else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$ *:: Int*

“Wahr oder Falsch” $\equiv \text{True} \vee \text{False} = \text{True}$ *:: Bool*

$(0 == 1) \wedge ((4 + 5) == 9) = \text{False}$

"Hello" ++ "World!" = "Hello World!"

$3 * \text{"Hello"} = ?$ *⚡*

$26 * 3^{2013} = 7245 \dots 2398$ *:: Int*

if 0 == 1 then 1 + 2 else 3 * 4 =

if 42 then "Richtig" else 5⁶ =

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$ *:: Int*

“Wahr oder Falsch” $\equiv \text{True} \vee \text{False} = \text{True}$ *:: Bool*

$(0 == 1) \wedge ((4 + 5) == 9) = \text{False}$ *:: Bool*

"Hello" ++ "World!" = "Hello World!"

$3 * \text{"Hello"} = ?$ *⚡*

$26 * 3^{2013} = 7245 \dots 2398$ *:: Int*

if $0 == 1$ then $1 + 2$ else $3 * 4 =$

if 42 then *"Richtig"* else $5^6 =$

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$:: <i>Int</i>
"Wahr oder Falsch" \equiv True \vee False = True	:: <i>Bool</i>
$(0 == 1) \wedge ((4 + 5) == 9) =$ False	:: <i>Bool</i>
"Hello" ++ "World!" = "Hello World!"	:: <i>String</i>
$3 * \text{"Hello"} = ?$	⚡
$26 * 3^{2013} = 7245 \dots 2398$:: <i>Int</i>
if 0 == 1 then 1 + 2 else 3 * 4 =	
if 42 then "Richtig" else 5 ⁶ =	

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$:: <i>Int</i>
"Wahr oder Falsch" \equiv True \vee False = True	:: <i>Bool</i>
$(0 == 1) \wedge ((4 + 5) == 9) =$ False	:: <i>Bool</i>
"Hello" ++ "World!" = "Hello World!"	:: <i>String</i>
$3 * \text{"Hello"} = ?$	⚡
$26 * 3^{2013} = 7245 \dots 2398$:: <i>Int</i>
if 0 == 1 then 1 + 2 else 3 * 4 = 12	:: <i>Int</i>
if 42 then "Richtig" else 5 ⁶ =	

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$:: <i>Int</i>
"Wahr oder Falsch" \equiv True \vee False = True	:: <i>Bool</i>
$(0 == 1) \wedge ((4 + 5) == 9) =$ False	:: <i>Bool</i>
"Hello" ++ "World!" = "Hello World!"	:: <i>String</i>
$3 * \text{"Hello"} = ?$	⚡
$26 * 3^{2013} = 7245 \dots 2398$:: <i>Int</i>
if 0 == 1 then 1 + 2 else 3 * 4 = 12	:: <i>Int</i>
if 42 then "Richtig" else $5^6 = ?$	

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$:: <i>Int</i>
"Wahr oder Falsch" \equiv True \vee False = True	:: <i>Bool</i>
$(0 == 1) \wedge ((4 + 5) == 9) =$ False	:: <i>Bool</i>
"Hello" ++ "World!" = "Hello World!"	:: <i>String</i>
$3 * \text{"Hello"} = ?$	⚡
$26 * 3^{2013} = 7245 \dots 2398$:: <i>Int</i>
if 0 == 1 then 1 + 2 else 3 * 4 = 12	:: <i>Int</i>
if 42 then "Richtig" else $5^6 = ?$	⚡

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was kommt heraus?

$2 + 3 = 5$:: <i>Int</i>
"Wahr oder Falsch" \equiv True \vee False = True	:: <i>Bool</i>
$(0 == 1) \wedge ((4 + 5) == 9) =$ False	:: <i>Bool</i>
"Hello" ++ "World!" = "Hello World!"	:: <i>String</i>
$3 * "Hello" = ?$	⚡
$26 * 3^{2013} = 7245 \dots 2398$:: <i>Int</i>
if 0 == 1 then 1 + 2 else 3 * 4 = 12	:: <i>Int</i>
if 42 then "Richtig" else $5^6 = ?$	⚡

⇒ Kenn wir den Typ, so kennen wir schon recht viel!

Was sind Typen?

- ▶ Ein Typ ist eine Menge von Werten
z.B. `Bool = {True, False}`, `Int = {1, 2, ...}`
- ▶ Viele Programmiersprachen erlauben eigene Typ-Definitionen
z.B. Aufzählungen, Tupel, etc.
- ▶ Ein Datenstruktur ist: ein Typ und Funktionen darauf
z.B. Listen mit Cons-Operation

Wozu sind Typen gut?

Robin Milner (1934-2010):

“Well-typed programs do not go wrong.”

Arten der Typprüfung:

Keine Schnell, aber Fehler werden nicht erkannt, was zu schweren Systemabstürzen führen kann

Assembler

Dynamisch Prüfung bei Ausführung — verlangsamt das Programm, aber Abbruch sobald Fehler passiert

Basic, Python, JavaScript

Statisch Verlangsamt nur Kompilieren, nicht Ausführung
Viele Fehler werden bereits vom Kompiler erkannt

Haskell, Scala, Java (teilw. dynamisch), C (unsicher)

- ▶ Typinferenz in vielen Sprachen möglich
- ▶ Typen dokumentieren auch

Formale Typprüfung

Typurteil allgemein:

$$\Gamma \vdash e : A$$

“Programmausdruck e hat den Typ A in Kontext Γ ”

Ein Kontext merkt sich die Typen von Variablen

$$\Gamma = \{i : Int, x : Float, s : String\}$$

Typregel-Beispiel: Konditional

$$\frac{\Gamma \vdash e_b : Bool \quad \Gamma \vdash e_t : String \quad \Gamma \vdash e_f : String}{\Gamma \vdash \text{if } e_b \text{ then } e_t \text{ else } e_f : String}$$

Erkennen des Fehlers:

```
if 42 then "Richtig" else 5.6
```

Probleme: $Int \neq Bool$

Formale Typprüfung

Typurteil allgemein:

$$\Gamma \vdash e : A$$

“Programmausdruck e hat den Typ A in Kontext Γ ”

Ein Kontext merkt sich die Typen von Variablen

$$\Gamma = \{i : Int, x : Float, s : String\}$$

Typregel-Beispiel: Konditional

$$\frac{\Gamma \vdash e_b : Bool \quad \Gamma \vdash e_t : String \quad \Gamma \vdash e_f : String}{\Gamma \vdash \text{if } e_b \text{ then } e_t \text{ else } e_f : String}$$

Erkennen des Fehlers:

```
if 42 then "Richtig" else 5.6
```

Probleme: $Int \neq Bool$, $String \neq Float$

Formale Typprüfung

Typurteil allgemein:

$$\Gamma \vdash e : A$$

“Programmausdruck e hat den Typ A in Kontext Γ ”

Ein Kontext merkt sich die Typen von Variablen

$$\Gamma = \{i : \text{Int}, x : \text{Float}, s : \text{String}\}$$

Typregel-Beispiel: Konditional

$$\frac{\Gamma \vdash e_b : \text{Bool} \quad \Gamma \vdash e_t : \text{String} \quad \Gamma \vdash e_f : \text{String}}{\Gamma \vdash \text{if } e_b \text{ then } e_t \text{ else } e_f : \text{String}}$$

Erkennen des Fehlers:

```
if 42 then "Richtig" else 5.6
     
   Int
```

Probleme: $\text{Int} \neq \text{Bool}$, $\text{String} \neq \text{Float}$

Formale Typprüfung

Typurteil allgemein:

$$\Gamma \vdash e : A$$

“Programmausdruck e hat den Typ A in Kontext Γ ”

Ein Kontext merkt sich die Typen von Variablen

$$\Gamma = \{i : Int, x : Float, s : String\}$$

Typregel-Beispiel: Konditional

$$\frac{\Gamma \vdash e_b : Bool \quad \Gamma \vdash e_t : A \quad \Gamma \vdash e_f : A}{\Gamma \vdash \text{if } e_b \text{ then } e_t \text{ else } e_f : A}$$

Erkennen des Fehlers:

`if 42 then "Richtig" else 5.6`
 String Float

Probleme: $Int \neq Bool$, $String \neq Float$

Listen

- ▶ geordnete Folge von Dingen gleichen Typs
 $[1, 2, 3], ['H', 'i', '!'], [True, False, False], [[1, 2], [3, 4, 5]]$
- ▶ Listen haben beliebige (endliche) Längen
- ▶ Erlauben Verarbeitung unbekannt vieler Daten
z.B. Klausuranmeldungen, Kontaktdatenbank im Handy
- ▶ Nur der Kopf der Liste kann bearbeitet werden
 - ▶ Neues Element vorne hinzufügen
 - ▶ Kopf abtrennen

Notation

- ▶ Leere Liste $[]$ (oder auch Nil)
- ▶ “Cons”-Operation : hat den Typ $A \rightarrow [A] \rightarrow [A]$

$$[1, 2, 3] = 1 : [2, 3] = 1 : (2 : [3]) = 1 : 2 : 3 : []$$

Beispiel: Listen-Länge berechnen

```
length :: [a] -> Int
length []     = 0
length (h:t) = 1 + length t
```

Warteschlange

- ▶ Kann beliebig viele Objekte speichern (wie Liste)
- ▶ Zuerst herein — zuerst heraus (FIFO: First In First Out)
- ▶ Puffer für Objekte

Zwei Operationen:

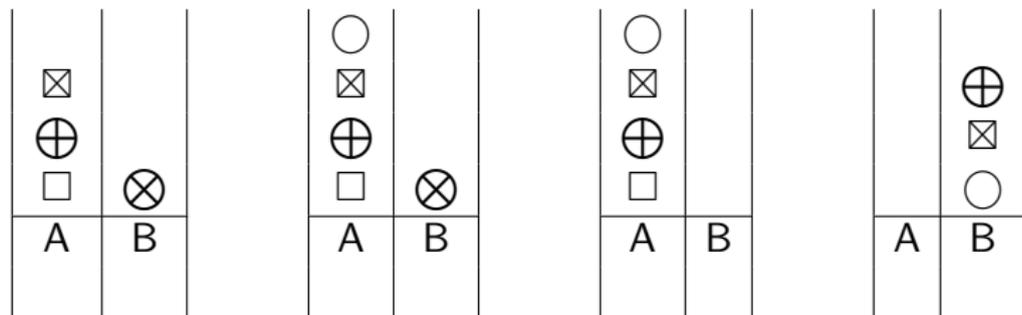
`enq :: a -> Queue a -> Queue a`

`deq :: Queue a -> (a, Queue a)`

Kann mithilfe von Listen implementiert werden.

Wie?

Warteschlange



op $\xrightarrow{\text{enq}(\bigcirc)}$ $\xrightarrow{\text{deq}() = \bigotimes}$ $\xrightarrow{\text{deq}() = \square}$

Warteschlange

```
data Queue a = Queue [a] [a]

enq :: a -> Queue a -> Queue a
enq x (Queue ins outs) = Queue (x:ins) outs

deq :: Queue a -> (a, Queue a)
deq (Queue ins (o:outs)) = (o, Queue ins outs )
deq (Queue ins [] ) = (h, Queue [] hs)
  where
    h:hs = umdrehen ins

umdrehen :: [a] -> [a]
umdrehen l = rev l []
  where
    rev [] a = a
    rev (x:xs) a = rev xs (x:a)
```

Begriffsklärung: “Komplexitätsanalyse mit Typen”

Wie schwierig ist ein Problem?

Wieviel Zeit (oder Speicherplatz) wird zur Lösung benötigt?

(in Abhängigkeit zur Problemgröße)

Komplexitätstheorie

Wie schwierig ist es generell, ein Problem zu Lösen?

- ▶ Konstante Faktoren irrelevant

Komplexitätsanalyse eines konkreten Programmes

Wie gut/schnell löst unser Programm ein Problem?

- ▶ Konstante Faktoren relevant

Analyse der Queue Operationen

Kosten der Warteschlangen Operationen:

⇒ Enq Kosten konstant



⇒ Deq Kosten hängen von Größe des Stack ab



Problem: Analyse muss den gesamten Zustand erfassen

- ▶ Simulation kann aufwendig sein
- ▶ Keine Sicherheit für unsimulierte Fälle

Analyse der Queue Operationen

Kosten der Warteschlangen Operationen:

Enq: 1

⇒ Enq Kosten konstant



⇒ Deq Kosten hängen von Größe des Stack ab



Problem: Analyse muss den gesamten Zustand erfassen

- ▶ Simulation kann aufwendig sein
- ▶ Keine Sicherheit für unsimulierte Fälle

Analyse der Queue Operationen

Kosten der Warteschlangen Operationen:

Enq: 1

Deq: 1

⇒ Enq Kosten konstant



⇒ Deq Kosten hängen von Größe des Stack ab



Problem: Analyse muss den gesamten Zustand erfassen

- ▶ Simulation kann aufwendig sein
- ▶ Keine Sicherheit für unsimulierte Fälle

Analyse der Queue Operationen

Kosten der Warteschlangen Operationen:

Enq: 1

Deq: 1

Deq: 5 ?

⇒ Enq Kosten konstant



⇒ Deq Kosten hängen von Größe des Stack ab



Problem: Analyse muss den gesamten Zustand erfassen

- ▶ Simulation kann aufwendig sein
- ▶ Keine Sicherheit für unsimulierte Fälle

Analyse der Queue Operationen

Kosten der Warteschlangen Operationen:

Enq: 1

Deq: 1

Deq: 5 ?

⇒ Enq Kosten konstant



⇒ Deq Kosten hängen von Größe des Stack ab



Problem: Analyse muss den gesamten Zustand erfassen

- ▶ Simulation kann aufwendig sein
- ▶ Keine Sicherheit für unsimulierte Fälle

Analyse der Queue Operationen

Kosten der Warteschlangen Operationen:

Enq: 1

Deq: 1

Deq: 5 ?

⇒ Enq Kosten konstant



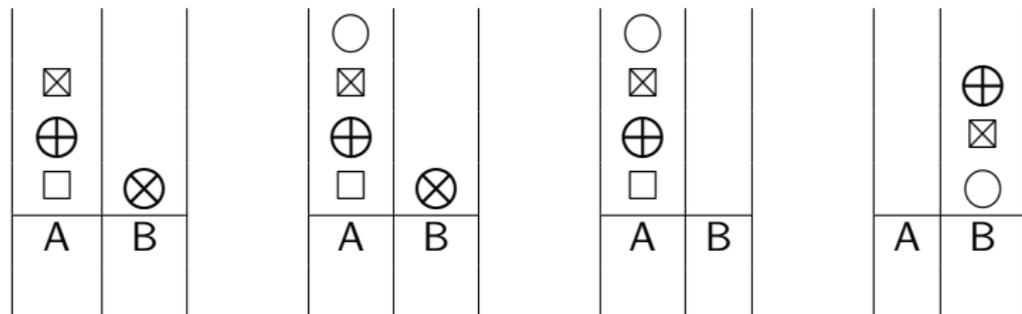
⇒ Deq Kosten hängen von Größe des Stack ab



Problem: Analyse muss den gesamten Zustand erfassen

- ▶ Simulation kann aufwendig sein
- ▶ Keine Sicherheit für unsimulierte Fälle

Warteschlange



op	$\xrightarrow{\text{enq}(\text{○})}$	$\xrightarrow{\text{deq}() = \text{⊗}}$	$\xrightarrow{\text{deq}() = \text{□}}$
Kosten	1	1	5

Lineares Gleichungssystem

e – Kosten von enq

d – Kosten von deq

a – Münzen in der A-Liste

b – Münzen in der B-Liste

$$e = 1 + a$$

$$d + b = 1$$

$$a = 1 + b$$

und $e \geq 0$, $d \geq 0$, $a \geq 0$, $b \geq 0$

Lineares Gleichungssystem

e – Kosten von enq

d – Kosten von deq

a – Münzen in der A-Liste

b – Münzen in der B-Liste

$$e = 1 + a$$

$$d + b = 1$$

$$a = 1 + b$$

$$3 = 1 + 2$$

$$0 + 1 = 1$$

$$2 = 1 + 1$$

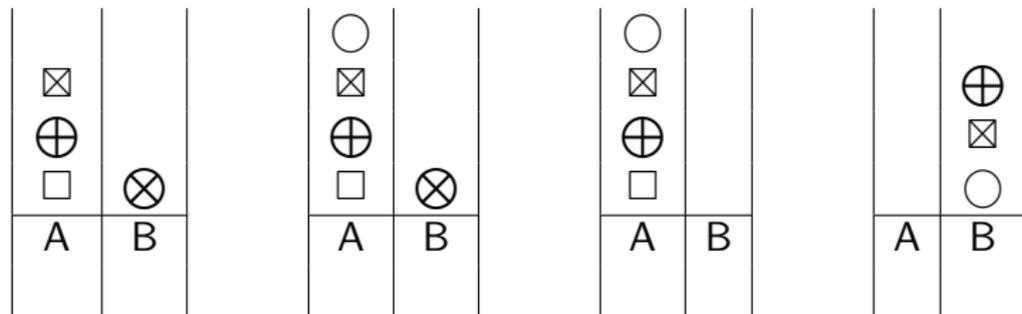
$$2 = 1 + 1$$

$$1 + 0 = 1$$

$$1 = 1 + 0$$

und $e \geq 0$, $d \geq 0$, $a \geq 0$, $b \geq 0$

Warteschlange



op	$\xrightarrow{\text{enq}(\text{○})}$	$\xrightarrow{\text{deq}() = \text{⊗}}$	$\xrightarrow{\text{deq}() = \text{□}}$
Kosten	1	1	5

Warteschlange

Φ	<table border="1"> <tr><td>A</td><td>B</td></tr> <tr><td>3</td><td>0</td></tr> </table>	A	B	3	0		<table border="1"> <tr><td>A</td><td>B</td></tr> <tr><td>4</td><td>0</td></tr> </table>	A	B	4	0		<table border="1"> <tr><td>A</td><td>B</td></tr> <tr><td>4</td><td>0</td></tr> </table>	A	B	4	0		<table border="1"> <tr><td>A</td><td>B</td></tr> <tr><td></td><td>0</td></tr> </table>	A	B		0
A	B																						
3	0																						
A	B																						
4	0																						
A	B																						
4	0																						
A	B																						
	0																						
op	$\xrightarrow{\text{enq}(\bigcirc)}$		$\xrightarrow{\text{deq}() = \bigotimes}$		$\xrightarrow{\text{deq}() = \square}$																		
Kosten	1		1		5																		

- ▶ Φ = Summe der “Münzen” in dieser Liste
- ▶ Konstante Kosten — macht Berechnen der Gesamtkosten einer Sequenz von Warteschlangen-Operationen viel leichter

Warteschlange

	⊠ ⊕ □	⊗		○ ⊠ ⊕ □	⊗		○ ⊠ ⊕ □			⊕ ⊠ ○	
	A	B		A	B		A	B		A	B
Φ	3	0		4	0		4	0		0	0

op	$\overrightarrow{\text{enq}(\circ)}$	$\overrightarrow{\text{deq}() = \otimes}$	$\overrightarrow{\text{deq}() = \square}$
Kosten	1	1	5
$\Delta\Phi$	1	0	-4
Σ	2	1	1

- ▶ Φ = Summe der "Münzen" in dieser Liste
- ▶ Konstante Kosten — macht Berechnen der Gesamtkosten einer Sequenz von Warteschlangen-Operationen viel leichter

Prinzip: Amortisierte Analyse

- ▶ Zustand zu Zahl reduzieren – *Potential* $\Phi(\text{Zustand})$
- ▶ Tatsächliche Kosten mit Potential bezahlen
 $\text{Kosten der Zustandsänderung} \leq \Phi(\text{vorher}) - \Phi(\text{nacher})$
- ▶ Gesamtkosten = Potential der Eingabe $\Phi(\text{Anfang})$

Kosten werden *früher* berechnet als sie anfallen

Grundidee 1985 gefunden von R.E. Tarjan,
erweitert 1998 von C. Okasaki

Von uns erweitert um

- ▶ Automatisierung vorher nur manuelle Anwendung
- ▶ Potential pro Referenz ohne Referenzen-Zählen

Erweiterte Typisierung + Lineare Gleichungen = Automatische Analyse

Prinzip: Amortisierte Analyse

- ▶ Zustand zu Zahl reduzieren – *Potential* $\Phi(\text{Zustand})$
- ▶ Tatsächliche Kosten mit Potential bezahlen
 $\text{Kosten der Zustandsänderung} \leq \Phi(\text{vorher}) - \Phi(\text{nacher})$
- ▶ Gesamtkosten = Potential der Eingabe $\Phi(\text{Anfang})$

Kosten werden *früher* berechnet als sie anfallen

Grundidee 1985 gefunden von R.E. Tarjan,
erweitert 1998 von C. Okasaki

Von uns erweitert um

- ▶ Automatisierung vorher nur manuelle Anwendung
- ▶ Potential pro Referenz ohne Referenzen-Zählen

Erweiterte Typisierung + Lineare Gleichungen = Automatische Analyse

Prinzip: Amortisierte Analyse

- ▶ Zustand zu Zahl reduzieren – *Potential* $\Phi(\text{Zustand})$
- ▶ Tatsächliche Kosten mit Potential bezahlen
 $\text{Kosten der Zustandsänderung} \leq \Phi(\text{vorher}) - \Phi(\text{nacher})$
- ▶ Gesamtkosten = Potential der Eingabe $\Phi(\text{Anfang})$

Kosten werden *früher* berechnet als sie anfallen

Grundidee 1985 gefunden von R.E. Tarjan,
erweitert 1998 von C. Okasaki

Von uns erweitert um

- ▶ Automatisierung vorher nur manuelle Anwendung
- ▶ Potential pro Referenz ohne Referenzen-Zählen

Erweiterte Typisierung + Lineare Gleichungen = Automatische Analyse

Prinzip: Amortisierte Analyse

- ▶ Zustand zu Zahl reduzieren – *Potential* $\Phi(\text{Zustand})$
- ▶ Tatsächliche Kosten mit Potential bezahlen
 $\text{Kosten der Zustandsänderung} \leq \Phi(\text{vorher}) - \Phi(\text{nacher})$
- ▶ Gesamtkosten = Potential der Eingabe $\Phi(\text{Anfang})$

Kosten werden *früher* berechnet als sie anfallen

Grundidee 1985 gefunden von R.E. Tarjan,
erweitert 1998 von C. Okasaki

Von uns erweitert um

- ▶ Automatisierung vorher nur manuelle Anwendung
- ▶ Potential pro Referenz ohne Referenzen-Zählen

Erweiterte Typisierung + Lineare Gleichungen = Automatische Analyse

Prinzip: Amortisierte Analyse

- ▶ Zustand zu Zahl reduzieren – *Potential* $\Phi(\text{Zustand})$
- ▶ Tatsächliche Kosten mit Potential bezahlen
 $\text{Kosten der Zustandsänderung} \leq \Phi(\text{vorher}) - \Phi(\text{nacher})$
- ▶ Gesamtkosten = Potential der Eingabe $\Phi(\text{Anfang})$

Kosten werden *früher* berechnet als sie anfallen

Grundidee 1985 gefunden von R.E. Tarjan,
erweitert 1998 von C. Okasaki

Von uns erweitert um

- ▶ Automatisierung vorher nur manuelle Anwendung
- ▶ Potential pro Referenz ohne Referenzen-Zählen

Erweiterte Typisierung + Lineare Gleichungen = Automatische Analyse

Automatisierung wichtig

Anwendung formaler Methoden gilt als teuer

— in der Praxis bisher nur selten benutzt

Die Zeiten ändern sich:

- ▶ Testen/Simulation wird immer schwieriger:
 - ▶ *App-Stores*: eine App für viele unterschiedliche Geräte
 - ▶ *Multi-Cores*: Anzahl der Testfälle explodiert hoffnungslos
- ▶ Kunden werden immer schwieriger
Handynutzer akzeptieren kein “Bluescreen”
- ▶ (Eingebettete) Softwaresystem sind allgegenwärtig

Automatisierung = Einfach/Billig = Weite Verbreitung

$$A ::= \text{unit} \mid \text{bool} \mid A \times A \mid (q; A) + (r; A) \mid \text{list}(q; A) \\ \mid A^{q \triangleright q'} \& B^{r \triangleright r'} \mid \forall \alpha \in \psi. A \xrightarrow{q \triangleright q'} A$$

with $q, q', r, r' \in RV$; $\alpha \subset RV$; ϕ set of linear constraints over RV

$$\frac{\phi = \{p = q + \text{TYPESIZE}(A \times \text{list}(q; A)), p' = 0\}}{x_h:A, x_t:\text{list}(q; A) \vdash_{p'}^p \text{Cons}(x_h, x_t) : \text{list}(q; A) \mid \phi} \\ (\text{ARTHUR} \vdash \text{LIST-CONS})$$

$$\frac{\Gamma \vdash_{p'}^p e_1 : C \mid \phi \quad \xi = \{p_0 = p + q + \text{TYPESIZE}(A \times \text{list}(q; A))\} \\ \Gamma, x_h:A, x_t:\text{list}(q; A) \vdash_{p'}^{p_0} e_2 : C \mid \psi}{\Gamma, x:\text{list}(q; A) \vdash_{p'}^p \text{match! } x \text{ with } \text{Nil} \rightarrow e_1 \quad : C \mid \phi \cup \psi \cup \xi \\ \mid \text{Cons}(x_h, x_t) \rightarrow e_2} \\ (\text{ARTHUR} \vdash \text{LIST-ELIM!})$$

$$\frac{\text{dom}(\Gamma) = \text{FV}(e) \setminus \{x, y\} \quad \alpha \cap (\text{FV}_\diamond(\Gamma) \cup \text{FV}_\diamond(\phi)) = \emptyset \quad \Gamma, x:A, y:\forall\alpha \in \psi. A \xrightarrow{q \triangleright q'} B \vdash_{q'} e : B \mid \xi \quad \phi \cup \psi \models \xi \quad \phi \models \{p = 1 + \text{TYPESIZE}(\Gamma), p' = 0\} \cup \bigcup_{D \in \text{ran}(\Gamma)} \forall(D \mid D, D)}{\Gamma \vdash_{p'}^p \text{rec } y = \text{fun } x \rightarrow e : \forall\alpha \in \psi. A \xrightarrow{q \triangleright q'} B \mid \phi}$$

(ARTHUR \vdash REC)

- predictable (minimal) closure size
- ensure newly bound variables are independent
- split constraints of ξ to delayed ψ and applied ϕ constraints
- allow repeated function application by zero closure potential

$$\sigma(B) = A \xrightarrow{r \triangleright r'} C$$

$\sigma : \alpha \rightarrow \text{RV}$ a substitution to fresh resource variables

$$\frac{x:A, y:\forall\alpha \in \psi. B \vdash_{q'}^q y x : C \mid \sigma(\psi) \cup \{r = q, r' = q'\}}{(\text{ARTHUR}\vdash\text{APP})}$$

Theorem der Korrektheit (vereinfacht)

WENN term e wohl-typisiert

v löst ψ

und e wertet aus zu ℓ

im konsistenten Anfangszustand

$$\Gamma \vdash_{q'}^q e : A \mid \psi$$

$$v \models \psi$$

$$\mathcal{S}, \mathcal{H} \vdash e \downarrow \ell, \mathcal{H}'$$

$$\mathcal{H} \models \mathcal{S} :: \Gamma$$

DANN

für alle $p \in \mathbb{N}$ mit

$$p \geq v(q) + \Phi_{\mathcal{H}}(\mathcal{S}; v(\Gamma))$$

gibt es ein $p' \in \mathbb{N}$ mit

$$p' \geq v(q') + \Phi_{\mathcal{H}'}(\ell; v(A))$$

SO DASS

e mit eingeschränkten Ressourcen auswertet

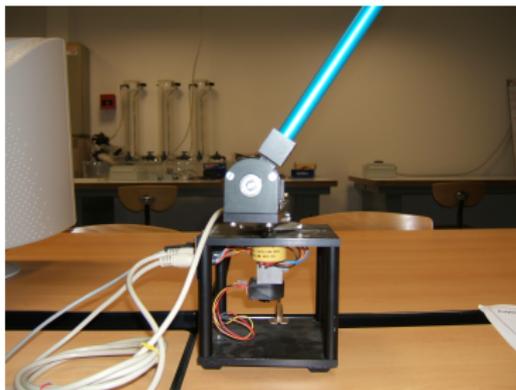
$$\mathcal{S}, \mathcal{H} \vdash_{p'}^p e \downarrow \ell, \mathcal{H}'$$

zu einem konsistenten Ergebnis

$$\mathcal{H}' \models \ell :: A$$

$$p, p' \in \mathbb{N}, \text{ aber } q, q' \in \mathbb{Q}^+$$

- ▶ Echtzeit-Regelung Problem (~ 190 lines)
- ▶ Durchgeführt und gemessen mit Renesas M32C/85U



- ▶ Ergebnis:
 - ▶ 36118 to 47635 Taktzyklen pro Schleife gemessen
 - ▶ 63678 Taktzyklen als oberere Schranke inferiert **33.7%**
 - ▶ *Stack Speicher*: **Exakte Vorhersage!**
 - ▶ *Dynamischer Speicher*: **Exakte Vorhersage!**
- ▶ 1115 lineare Gleichungen über 2214 Variablen erzeugt in 0.41s, gelöst in 0.26s mit 1.73Ghz Pentium M, 2MB cache

Verständliche Ergebnisse

Beispiel: RBinsert: int, rbtree -> rbtree

Ergebnis der Analyse:

ARTHUR3 typing for HumeHeapBoxed:

```
(int,rbtree[Leaf|Node<10>:colour[Red|Black<18>],#,int,#])  
  -(20/0)->  rbtree[Leaf|Node:colour[Red|Black],#,int,#]
```

Automatische Übersetzung in natürliche Sprache:

Worst-case Heap-units required to call RBinsert:

$$20 + 10 \cdot X1 + 18 \cdot X2$$

where

X1 = number of "Node" nodes at 1. position

X2 = number of "Black" nodes at 1. position

Bemerge: Daten-Abhängige Schranken berechnet,
nicht nur Größen-Abhängig

Forschungsergebnisse

Past

LFPL to malloc-free C	Hofmann, Nordic'00
Heap Usage for First-Order Language	Hofmann & Jost, POPL'03
Java & Storeless Semantics	Hofmann & Jost, ESOP'06
Java Automated Type-Checking	Hofmann & Rodriguez, EACSL'09
Stack Space Usage & Depth	Campbell, ESOP'09
WCET, Algebraic Datatypes & Cost Genericity	Jost et al., FM'09
Higher-order & Polymorphism	Jost et al., POPL'10
Polynomial Bounds	Hofmann & Hoffmann, ESOP'10
Lazy Evaluation	Simões et al. ICFP'12

Future

- Combination with Sized Types
- Negative Potential
- Potential for Numeric Types

Zusammenfassung

- ▶ Mathematik/Theoretische Informatik ist toll!
- ▶ Typen sind toll!
- ▶ Automatische Analysen sind toll
 - wenn deren Korrektheit formell bewiesen wurde