

Script generated by TTT

Title: Simon: Compilerbau (13.06.2012)

Date: Wed Jun 13 14:05:05 CEST 2012

Duration: 74:01 min

Pages: 27

Die semantische Analyse

Kapitel 3: Typ-Überprüfung

55 / 184

Ziel der Typ-Überprüfung

In modernen (imperativen / objektorientierten / funktionalen) Programmiersprachen besitzen Variablen und Funktionen einen Typ, z.B. int, void*, struct { int x; int y; }.

Typen sind nützlich für:

- die Speicherverwaltung;
- die Vermeidung von Laufzeit-Fehlern

In imperativen / objektorientierten Programmiersprachen muss der Typ bei der Deklaration spezifiziert und vom Compiler die typ-korrekte Verwendung überprüft werden.

56 / 184

Typ-Ausdrücke

Typen werden durch Typ-*Ausdrücke* beschrieben.
Die Menge T der Typausdrücke enthält:

- 1 Basis-Typen: int, char, float, void, ...
- 2 Typkonstruktoren, die auf Typen angewendet werden

Beispiele für Typkonstruktoren:

- Verbunde: struct { t_1 a_1 ; ... t_k a_k ; }
- Zeiger: t *
- Felder: t [n]
 - in C kann/muss zusätzlich eine Größe spezifiziert werden
 - die Variable muss zwischen t und [n] stehen
- Funktionen: t (t_1, \dots, t_k) |
 - in C muss die Variable zwischen t und (t_1, \dots, t_k) stehen.
 - in ML würde man diesen Typ anders herum schreiben:
 $t_1 * \dots * t_k \rightarrow t$ $t_1 \rightarrow (t_2 \rightarrow (\dots \rightarrow (t_k \rightarrow t)))$
- wir benutzen (t_1, \dots, t_k) als Tupel-Typen

57 / 184

Typ-Namen

Ein Typ-Name ist ein *Synonym* für einen Typ-Ausdruck.
In C kann man diese mit Hilfe von typedef einführen.
Typ-Namen sind nützlich

- als Abkürzung:

```
typedef struct { int x; int y; } point_t;
```

- zur Konstruktion rekursiver Typen:

Erlaubt in C: *struct k **

```
struct list {
  int info;
  struct list* next;
}
```

```
struct list* head;
```

Lesbarer:

```
typedef struct list list_t;
```

```
struct list {
  int info;
  list_t* next;
}
```

```
list_t* head;
```

58/184

Typ-Prüfung

Aufgabe:

$(t_1, x_1), \dots$

Gegeben: eine Menge von Typ-Deklarationen $\Gamma = \{t_1, x_1; \dots, t_m, x_m\}$

Überprüfe: Kann ein Ausdruck e mit dem Typ t versehen werden?

Beispiel:

$x = a$

```
struct list { int info; struct list* next; };
int f(struct list* l) { return l; };
struct { struct list* c; } * b;
int* a[11];
```


Betrachte den Ausdruck:

*a[f(b->c)]+2;

59/184

Typ-Prüfung am Syntax-Baum

Prüfe Ausdruck *a[f(b->c)]+2;



Idee:

- traversiere den Syntaxbaum bottom-up
- für Bezeichner schlagen wir in Γ den richtigen Typ nach
- Konstanten wie 2 oder 0.5 sehen wir den Typ direkt an
- die Typen für die inneren Knoten erschießen wir mit Hilfe von Typ-Regeln

60/184

Typ-Systeme

Formal betrachten wir *Aussagen* der Form:

$\Gamma \vdash e : t$

// (In der Typ-Umgebung Γ hat e den Typ t)

*Structured
Operational
Semantics*

Prämisse

Schlussfolgerung

Axiome:

$$\frac{e \in \mathcal{T} \quad x \in \mathcal{Z}}{\Gamma \vdash x : \text{int}}$$

Const: $\frac{\Gamma \vdash c : t_c}{\Gamma \vdash c : t_c}$

(t_c Typ der Konstante c)

Var: $\frac{\Gamma \vdash x : \Gamma(x)}{\Gamma \vdash x : \Gamma(x)}$

(x Variable)

Regeln:

Ref: $\frac{\Gamma \vdash e : t \quad \Gamma \vdash e : t}{\Gamma \vdash e : t}$

Deref: $\frac{\Gamma \vdash e : \Gamma^* \quad \Gamma \vdash *e : t}{\Gamma \vdash e : t}$

61/184

Typ-System für C-ähnliche Sprachen

Weitere Regeln für diverse Typausdrücke:

Array: $\frac{\Gamma \vdash e_1 : t^* \quad \Gamma \vdash e_2 : \text{int}}{\Gamma \vdash e_1[e_2] : t}$ *$\Gamma \vdash e_2 : \text{int}$*

Array: $\frac{\Gamma \vdash e_1 : t[] \quad \Gamma \vdash e_2 : \text{int}}{\Gamma \vdash e_1[e_2] : t}$

Struct: $\frac{\Gamma \vdash e : \text{struct } \{t_1 a_1; \dots; t_m a_m;\}}{\Gamma \vdash e.a_i : t_i}$ *head.info: int*

App: $\frac{\Gamma \vdash e : t(t_1, \dots, t_m) \quad \Gamma \vdash e_1 : t_1 \dots \Gamma \vdash e_m : t_m}{\Gamma \vdash e(e_1, \dots, e_m) : t}$ *$\Gamma \vdash e_1 : \text{float}$ $\Gamma \vdash e_2 : \text{int}$*

Op: $\frac{\Gamma \vdash e_1 : \text{int} \quad \Gamma \vdash e_2 : \text{int}}{\Gamma \vdash e_1 + e_2 : \text{int}}$ *$\Gamma \vdash e_1 + e_2 : \text{float}$*


Cast: $\frac{\Gamma \vdash e : t_1 \quad t_1 \text{ in } t_2 \text{ konvertierbar}}{\Gamma \vdash (t_2) e : t_2}$

Beispiel: Typ-Prüfung

Ausdruck $*a[f(b \rightarrow c)] + 2$ und $\Gamma = \{$

```

struct list { int info; struct list* next; };
int f(struct list* l);
struct { struct list* c;}* b;
int* a[11];
};
    
```



Typ-System für C-ähnliche Sprachen

Weitere Regeln für diverse Typausdrücke:

Array: $\frac{\Gamma \vdash e_1 : t^* \quad \Gamma \vdash e_2 : \text{int}}{\Gamma \vdash e_1[e_2] : t}$

Array: $\frac{\Gamma \vdash e_1 : t[] \quad \Gamma \vdash e_2 : \text{int}}{\Gamma \vdash e_1[e_2] : t}$

Struct: $\frac{\Gamma \vdash e : \text{struct } \{t_1 a_1; \dots; t_m a_m;\}}{\Gamma \vdash e.a_i : t_i}$

App: $\frac{\Gamma \vdash e : t(t_1, \dots, t_m) \quad \Gamma \vdash e_1 : t_1 \dots \Gamma \vdash e_m : t_m}{\Gamma \vdash e(e_1, \dots, e_m) : t}$

Op: $\frac{\Gamma \vdash e_1 : \text{int} \quad \Gamma \vdash e_2 : \text{int}}{\Gamma \vdash e_1 + e_2 : \text{int}}$

Cast: $\frac{\Gamma \vdash e : t_1 \quad t_1 \text{ in } t_2 \text{ konvertierbar}}{\Gamma \vdash (t_2) e : t_2}$

Beispiel: Typ-Prüfung $(*b).c$

Ausdruck $*a[f(b \rightarrow c)] + 2$ und $\Gamma = \{$

```

struct list { int info; struct list* next; };
int f(struct list* l);
struct { struct list* c;}* b;
int* a[11];
};
    
```

$\Gamma \vdash b : \text{struct } \{ \text{struct list* } c; \}^*$ *Decl*

$\Gamma \vdash f : \text{int } (\text{struct list}^*)$ *Struct*

$\Gamma \vdash (*b).c : \text{struct list}^*$ *App* (7)

$\Gamma \vdash f((*)b).c : \text{int}$ *App*

$\Gamma \vdash a[f(b \rightarrow c)] : \text{int}^*$ *Decl*


$\Gamma \vdash *a[f(b \rightarrow c)] : \text{int}$ *Decl*

$\Gamma \vdash (*a[f(b \rightarrow c)] + 2) : \text{int}$ *Decl*

$\Gamma \vdash (*a)$ *Decl*

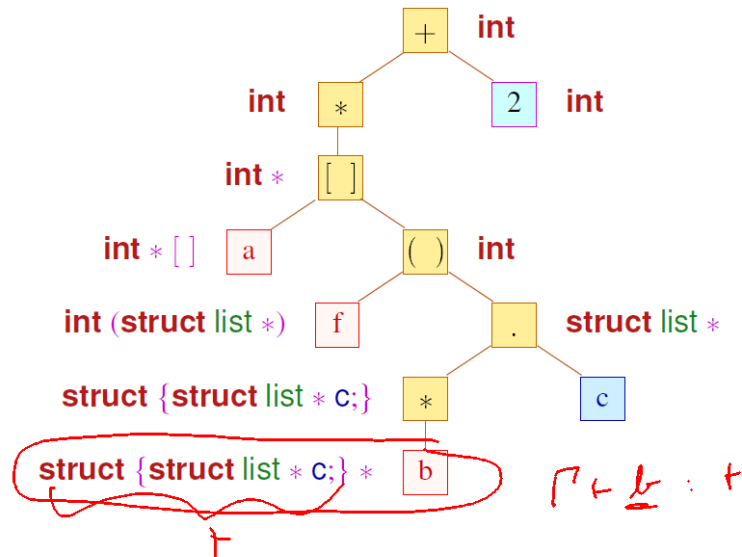
$\Gamma \vdash a : \text{int}^*[]$ *Id*

$(*)b.c$



Beispiel: Typ-Prüfung

Ausdruck `*a [f (b->c)] + 2`:



64/184

Gleichheit von Typen

Zusammenfassung Typprüfung:

- Welche Regel an einem Knoten angewendet werden muss, ergibt sich aus den Typen für die bereits bearbeiteten Kinderknoten
- Dazu muss die Gleichheit von Typen festgestellt werden.

Typgleichheit in C:

- struct A { } und struct B { } werden als verschieden betrachtet
 - \leadsto der Compiler kann die Felder von A und B nach Bedarf umordnen (in C nicht erlaubt)
 - um einen Verband A um weitere Felder zu erweitern, muss er eingebettet werden:

```
typedef struct B {
    struct A a;
    int field_of_B;
} extension_of_A;
```

extension_of_A a. f

- Nach typedef int C; haben C und int den gleichen Typ.

65/184

Strukturelle Typ-Gleichheit

Alternative Interpretation von Gleichheit (*gilt nicht in C*):

Semantisch können wir zwei rekursive Typen t_1, t_2 als *gleich* betrachten, falls sie die gleiche Menge von Pfaden zulassen.

Beispiel:

```
struct list {
    int info;
    struct list* next;
}

struct list1 {
    int info;
    struct {
        int info;
        struct list1* next;
    } * next;
}
```

Sei `struct list* l` oder `struct list1* l`. Beide erlauben

`l->info l->next->info`

jedoch hat `l` jeweils einen anderen Typen in C.

66/184

Algorithmus zum Test auf Semantische Gleichheit

Idee:

- Verwalte Äquivalenz-Anfragen für je zwei Typausdrücke
- Sind die beiden Ausdrücke syntaktisch gleich, ist alles gut
- Andernfalls reduziere die Äquivalenz-Anfrage zwischen Äquivalenz-Anfragen zwischen (hoffentlich) einfacheren anderen Typausdrücken


Nehmen wir an, rekursive Typen würden mit Hilfe von Typ-Gleichungen der Form:

$A = T$

eingeführt (verzichte auf ein T). Dann definieren wir folgende Regeln:

67/184

Regeln für Wohlgetyptheit



Beispiel:

```

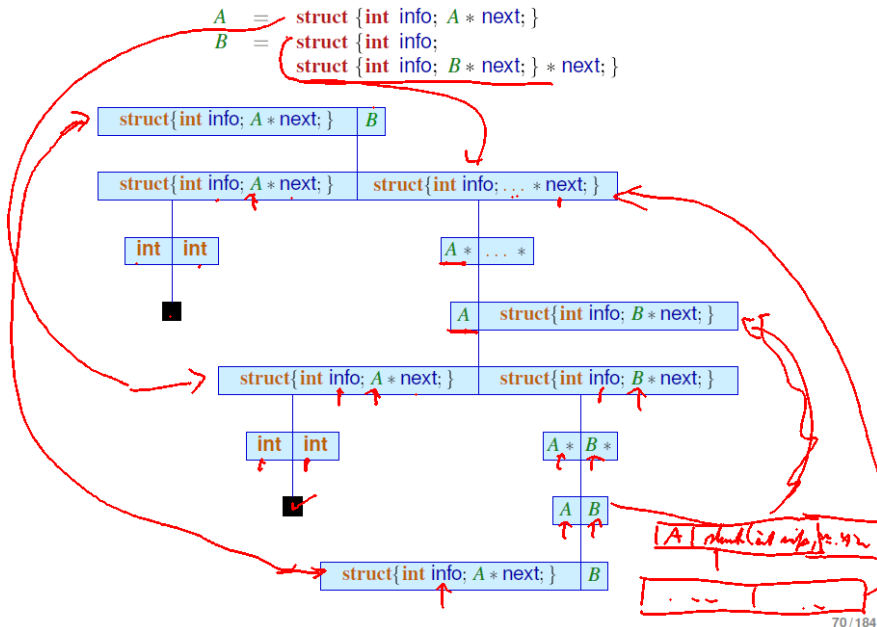
A = struct {int info; A * next; }
B = struct {int info;
  struct {int info; B * next; } * next; }
  
```

Wir fragen uns etwa, ob gilt:

$\text{struct } \{\text{int info; } A * \text{next;}\} = B$

Dazu konstruieren wir:

Beweis Beispiel:



Implementierung

- Stoßen wir bei der Konstruktion des Beweisbaums auf eine Äquivalenz-Anfrage, auf die keine Regel anwendbar ist, sind die Typen ungleich
- Die Konstruktion des Beweisbaums kann dazu führen, dass die gleiche Äquivalenz-Anfrage ein weiteres Mal auftritt
- Taucht eine Äquivalenz-Anfrage ein weiteres Mal auf, sind die Typen der Anfrage per Definition gleich

Terminierung?

Implementierung

- Stoßen wir bei der Konstruktion des Beweisbaums auf eine Äquivalenz-Anfrage, auf die keine Regel anwendbar ist, sind die Typen *ungleich*
- Die Konstruktion des Beweisbaums kann dazu führen, dass die gleiche Äquivalenz-Anfrage ein weiteres Mal auftritt
- Taucht eine Äquivalenz-Anfrage ein weiteres Mal auf, sind die Typen der Anfrage per Definition gleich

Terminierung?

- die Menge D aller deklarierten Typen ist endlich
- es gibt höchstens $|D|^2$ viele Äquivalenzanfragen
- wiederholte Anfragen sind automatisch erfüllt

~> Terminierung ist gesichert

71/184

Überladung und Koersion

Manche Operatoren wie z.B. $+$ sind *überladen*:

- $+$ besitzt *mehrere mögliche* Typen
Zum Beispiel: $\text{int} + (\text{int}, \text{int}), \text{float} + (\text{float}, \text{float})$
aber auch $\text{float}^* + (\text{float}^*, \text{int}), \text{int}^* + (\text{int}, \text{int}^*)$
- je nach Typ hat der Operator $+$ eine unterschiedliche Implementation
- welche Implementierung ausgewählt wird, entscheiden die Argument-Typen

72/184

Überladung und Koersion

Manche Operatoren wie z.B. $+$ sind *überladen*:

- $+$ besitzt *mehrere mögliche* Typen
Zum Beispiel: $\text{int} + (\text{int}, \text{int}), \text{float} + (\text{float}, \text{float})$
aber auch $\text{float}^* + (\text{float}^*, \text{int}), \text{int}^* + (\text{int}, \text{int}^*)$
- je nach Typ hat der Operator $+$ eine unterschiedliche Implementation
- welche Implementierung ausgewählt wird, entscheiden die Argument-Typen

Koersion: Erlaube auch die Anwendung von $+$ auf int und float .

- anstatt $+$ für alle Argument-Kombinationen zu definieren, werden die Typen der Argumente *konvertiert*
- Konvertierung kann Code erzeugen (z.B. Umwandlung von int nach float)
 $i : e : \text{int}$
 $f : e : \text{float}$
- Konvertiert wird in der Regel auf die Supertypen, d.h. $5+0.5$ hat Typ float (da $\text{float} \geq \text{int}$)

72/184

Koersion von Integer-Typen in C: Promotion

C enthält spezielle Koersionsregeln für Integer: *Promotion*

unsigned char \leq unsigned short \leq int \leq unsigned int
signed char \leq signed short

... wobei eine Konvertierung über alle Zwischentypen gehen muss.

73/184

Koersion von Integer-Typen in C: Promotion

C enthält spezielle Koersionsregeln für Integer: Promotion

`unsigned char` `signed char` \leq `unsigned short` `signed short` \leq `int` \leq `unsigned int`

signed *2³²-40-1*

... wobei eine Konvertierung über alle Zwischentypen gehen muss.

Subtile Fehler möglich! Berechne Zeichenverteilung in `char* str`:

```
char* str = "...";  
int dist[256];  
memset(dist, 0, sizeof(dist));  
while (*str) {  
    dist[(unsigned) *str]++;  
    str++;  
};
```

Beachte: `unsigned` bedeutet `unsigned int`.

'k' = -40

73/184

Ausblick

Registerverteilung hat weitere Aufgaben:

- unnötige `move` Instruktionen müssen vermieden werden
- Variablen müssen auf den Stack ausgelagert werden
 - \sim evtl. benötigt dies wiederum Register
- übersetze Funktionen in eine `single static assignment` Form
- optimale Färbung möglich (allerdings müssen evtl. Register getauscht werden)

\sim Vorlesung Programmoptimierung

Schematisch präsentierte liveness-Analyse verbesserungsfähig:

- nach $x \leftarrow y + 1$ ist x nur lebendig wenn y lebendig ist
- `saveloc` hält Register unnötig am Leben \sim Zwischensprache
- gibt es *optimale* Regeln für die liveness-Analyse?

\sim Vorlesung Programmoptimierung

Wie berechnet man die liveness Mengen, Registerverteilung zügig?

\sim Vorlesung Programmoptimierung

184/184

Typ-Prüfung am Syntax-Baum
Prüfe Ausdruck `*a[f(b->c)]+2`:

Idee:

- traversiere den Syntaxbaum **bottom-up**
- für Bezeichner schlagen wir in Γ den richtigen Typ nach
- Konstanten wie 2 oder 0.5 sehen wir den Typ direkt an
- die Typen für die inneren Knoten erschließen wir mit Hilfe von Typ-Regeln

int \leq float

60/184

Beispiel: Teiltypen

Betrachte:

```
string extractInfo( struct { string info; } x) {  
    return x.info;  
}
```

- Wir möchten dass `extractInfo` für alle Argument-Strukturen funktioniert, die eine Komponente string info besitzen
- Wann $t_1 \leq t_2$ gelten soll, beschreiben wir durch Regeln
- Die Idee ist vergleichbar zur Anwendbarkeit auf Unterklassen (aber allgemeiner)

75/184