

Tipi e sicurezza dei tipi

Angelo Gargantini
informatica III
cap 6 del mitchell

La sicurezza dei tipi nei linguaggi di programmazione

La sicurezza dei tipi in un programma è molto importante

- se l'esecutore (il PC o la macchina virtuale) non riesce a distinguere i tipi di un certo programma può facilmente causare errori
- molti attacchi sfruttano proprio debolezze nel controllo dei tipi di linguaggi diffusi come il C

"Well-typed programs never go wrong."

Robert Milner

Tipo

Tipo: Insieme di valori omogenei + operazioni che si possono fare

Esempi:

- tipi semplici: Integers, String,
- tipi strutturati come classi, ...
- funzioni: int -> bool
 - Funzione che da un intero mi dà un boolean
 - Anche le funzioni e i metodi definisco un tipo

Esempi di non tipi:

- numeri dispari
- array contenenti String e Integer

Dipende però dal linguaggio di programmazione

A cosa servono i tipi

Per **organizzare** e dare un nome ai concetti (documentazione)

- Spesso corrispondenti ai concetti nel dominio del problema che si vuole risolvere
- Indicare l'uso che si vorrà fare di certi identificatori (così il compilatore può controllare)

Per **assicurarsi** che sequenze di bit in memoria siano interpretate correttamente

- Per evitare errori come: `3 + true + "Angelo"`

Per **istruire il compilatore** come rappresentare i dati

- Esempio short richiedono meno bit di int

Errori di tipi a livello Hardware

Confondere **dati con programmi**

- Caricando quindi nei registri della CPU possibilmente codici non corretti

Esempio: cerco di eseguire un dato chiamando **x()** dove **x** non è una procedura ma un intero

Confondere **tipi di dati semplici**

Esempio: eseguo **float_add(3,4.5)** con 3 int
float_add: operazione della CPU che chiama una routine della FPU, se la CPU prende 3 come sequenza di bit float, potrebbe generare un errore hardware

Errori semantici

Il programma fa qualcosa che non è quello che dovrebbe fare

- Esempio con tipi primitivi: `int_add(3, 4.5)`

In questo caso la sequenza di bit che rappresenta 4.5 può essere interpretato come int ma non sarà uguale come valore

- Esempio con oggetti ed ereditarietà in Java

Sia Quadrato sottoclasse di Figura:

```
class Quadrato extends Figura
```

Se non riesco a distinguere istanze di Qu. e Fig.:

```
Figura a1 = new Quadrato() OK
```

```
Quadrato b1 = new Figura() NO: Quadrato potrebbe  
avere dei metodi in più che potrei invocare ma non trovare  
perché b1 è una Figura
```

Type safety: sicurezza dei tipi

Un linguaggio di programmazione L si dice **type safe** se non esiste programma scritto in L che possa violare la distinzione di tipi in L

Esempi di violazioni dei tipi:

- confondere interi e float
- chiamare una funzione attraverso un intero
- accedere ad una zona di memoria sbagliata (**non memory safe**)

Sicurezza di alcuni linguaggi

Ecco una tabella che riporta la sicurezza di alcuni linguaggi di programmazione molto diffusi

Safety	Linguaggio	Motivo
Non safe	C e C++	Type cast, aritmetica dei puntatori
Quasi safe	Pascal	Deallocazione esplicita e dangling pointers
Safe	Java, Lisp	Controllo completo dei tipi

Problemi del C/C++

Il C/C++ ha un sistema dei tipi non sicuro (posso facilmente violare la distinzione di tipi)

Alcuni tipi errori

- Type cast
- Pointer arithmetic
- Accesso alla memoria non valida
 - Violazione **spaziale** come out of bound
 - Violazione **temporale** come dangling pointers
- Dereferenziazione del null, ...

Quando si fa il type checking?

Tra i linguaggi **type safe** distinguiamo due categorie a seconda del **momento** in cui avviene il controllo dei tipi

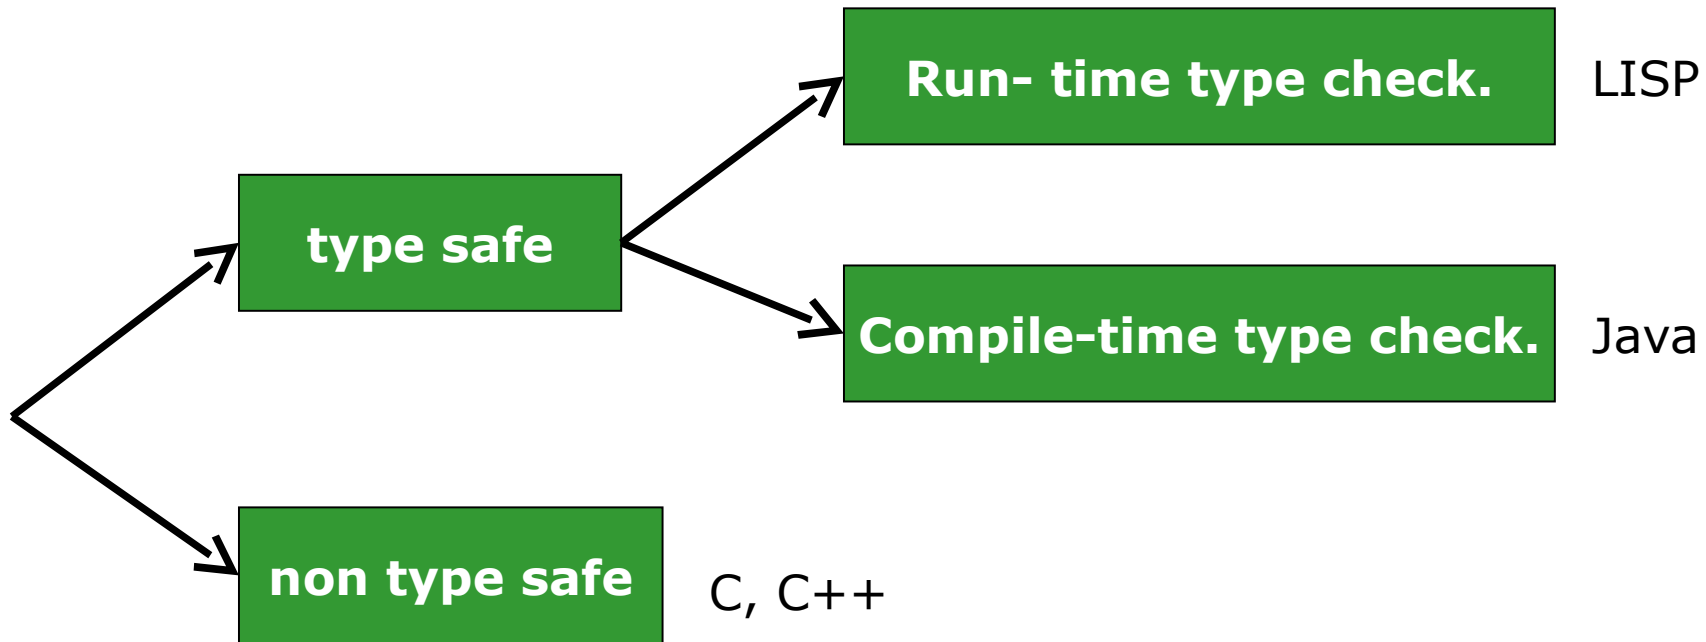
run-time type checking

- Il controllo avviene durante l'esecuzione
- Esempio LISP: quando esegue l'istruzione (car x) - che applica car a x e car restituisce il primo elemento di una lista - controlla prima che x sia una lista

compile time type checking

- Il controllo avviene durante la compilazione
- Esempio ML: se compila $f(x)$ controlla che se f sia $A \rightarrow B$ e $x : A$

Classificazione dei linguaggi



Java

Java usa **compile time**, però dove il compilatore non è sicuro della sicurezza dei tipi, introduce un controllo run-time (**conversioni dei tipi controllate**)

considera la seguente istruzione

```
Quadrato a = (Quadrato) b
```

- con b dichiarato di classe Figura (padre di Quad.)
- la conversione al sottotipo `Quadrato` è corretta solo se **b è effettivamente una istanza di** `Quadrato` (o di una sottoclasse)
- tale controllo non si può fare in compilazione
- il compilatore introduce un controllo da fare durante l'esecuzione che b sia convertibile a `Quadrato`

Pro e contro

Entrambi gli approcci (run-time e compile time) prevengono errori di tipo, però:

- run-time checking rallenta l'esecuzione
 - controlla le conversioni di tipo ogni volta
- compile-time checking limita la flessibilità dei programmi
 - tutte le istruzioni anche non eseguite devono essere corrette

alcuni programmi che non sono corretti compile time sono invece run time corretti

Flessibilità del run time chkng

In Lisp, possiamo scrivere

```
(cond ((< x 10) x) (else (car x))) OK
```

alcune volte ci sarà errore (catturato dal lisp stesso) altre no - se x non è < 10 valuto car che si aspetta una lista

In Java, **non** posso scrivere

```
int x;
```

```
if (0 > -1) { x++; } else { x = "ciao"; } NO
```

perché assegna ad x int una String

eppure questo programma è type safe, perché nessuna esecuzione causa errori di tipo (0 è sempre > -1)

In sintesi

- Abbiamo visto:
 - l'importanza della sicurezza dei tipi
 - la definizione di linguaggio sicuro nei tipi
 - alcuni linguaggi sono safe altri no
- Ricordate che:
 - il C non è type safe – vedremo la prossima lezione alcuni errori tipici
- Inoltre,
 - i linguaggi safe possono effettuare il controllo dei tipi o durante l'esecuzione (run-time) come il LISP o durante la compilazione (compile-time) come Java
 - i pro e contro dei due approcci sono: flessibilità (maggiore con runtime) e efficienza (maggiore con compile time)

“C is not Safe”

Alcune caratteristiche del linguaggio C e C++ che **possono** dare errori:

- dereferenziazione del null
- type cast non controllato
- pointer arithmetic
- accesso alla memoria non valida
 - violazione **spaziale** come out of bound
 - violazione **temporale** come dangling pointers

Queste caratteristiche rendono il C molto **flessibile** e **veloce** a discapito della sua sicurezza

- è responsabilità del programmatore stare attento a non introdurre difetti

Ripasso del C

```
#include <stdio.h>
```

Dichiarazioni di import /preprocessore

```
int main()
```

Dichiarazioni di funzioni

```
{
```

```
printf("Hello, World!\n");
```

```
return(0);
```

```
}
```

Tipi in C

- Per dichiarare una variabile si scrive:
var_tipo elenco-variabili-separate-da-virgole ;
- Le variabili globali si definiscono al di sopra della funzione main(), nel seguente modo:

```
short number, sum;  
int bignumber, bigsum;  
char letter;  
main() { }
```

- E' possibile preinizializzare una variabile utilizzando = (operatore di assegnazione).

typedef

- Si possono definire nuovi propri tipi di variabili utilizzando "typedef"(questo risulta utile quando si creano strutture complesse di dati).
- Ad esempio:
 - `typedef float real;`
 - `typedef char letter;`
- variabili dichiarate:
 - `real sum=0.0;`
 - `letter nextletter;`

puntatori

- Un puntatore e' un tipo di dato, una variabile che contiene l'indirizzo in memoria di un'altra variabile. Si possono avere puntatori a qualsiasi tipo di variabile.
 - La dichiarazione di un puntatore include il tipo dell'oggetto a cui il puntatore punta.
 - L' operatore & (operatore unario, o monadico) fornisce l'indirizzo di una variabile.
 - L' operatore * (operatore indiretto, o non referenziato) da' il contenuto dell'oggetto a cui punta un puntatore.
- Per dichiarare un puntatore ad una variabile, l'istruzione e':
- `<tipo> *<var>;`
- es: `int *pointer;`

Esempi

- `int *pointer; /* dichiara pointer come un puntatore a int */`
- `int x=1,y=2;`
- `pointer= &x; /* assegna a pointer l'indirizzo di x */`
- `y=*pointer; /* assegna a y il contenuto di pointer */`
- `x=pointer /* assegna ad x l'indirizzo contenuto in pointer */`
- `*pointer=3; /* assegna al contenuto di pointer il valore 3 */`

Aritmetica dei puntatori /array

- Un'array di elementi puo' essere pensato come disposto in un insieme di locazioni di memoria consecutive.

```
int a[10], x;
```

```
int *ptr;
```

```
ptr=&a[0]; /* ptr punta all'indirizzo di a[0] */
```

```
x=*ptr; /* x = contenuto di ptr (in questo caso, a[0]) */
```

- A questo punto potremo incrementare ptr con successive istruzioni

```
++ptr
```

- ma potremo anche avere

```
(ptr + i)
```

- che e' equivalente ad $a[i]$, con $i=0,1,2,3...9$.

malloc

- La funzione malloc resituisce nuova memoria
- `char *malloc(int number_of_bytes)`
 - Es. `char *cp; cp = malloc(100);`
- Se si vuole avere un puntatore ad un altro tipo di dato, si deve utilizzare la coercizione. Inoltre solitamente viene utilizzata la funzione `sizeof()`
- `int *ip;`
- `ip = (int *) malloc(100*sizeof(int));`

Dereferenziazione di null

- La dereferenziazione di un puntatore in C non viene controllata
- Se accedo ad una cella puntata da un puntatore nullo ho “segmentation fault”, cioè un errore del sistema operativo

Programma con accesso tramite puntatore null

```
int main() {  
    int * ptr;  
    ptr = 0;  
    *ptr = 2;  
}
```


TypeCast non Safe

Il C permette la conversione **non controllata** da un tipo ad un altro:

- da un tipo ad un sopratipo con possibile perdita di informazioni.
- da intero ad una funzione per cercare di eseguire una certa locazione di memoria che potrebbe non essere un'istruzione corretta o fare qualcosa di non voluto

Programma corretto in C ma con type cast non safe:

```
double d;  
int i;
```

...

```
i = d; ➔ possibile perdita di informazioni
```

Pointer arithmetic

Mediante l'aritmetica dei puntatori possiamo puntare a zone di memoria con tipi diversi

Esempio:

- se il puntatore p è definito di tipo A^*
- l'espressione $*(p+i)$ ha tipo A
- poiché il valore memorizzato a $p+i$ potrebbe avere qualsiasi tipo
- l'assegnamento $x = *(p+i)$ con x di tipo A , permette di memorizzare un valore di qualsiasi tipo in x

C non è memory safe

Inoltre mediante i puntatori si può facilmente accedere a memoria in modo scorretto

```
void f(int* p, int i, int v) {  
    p[i] = v;  
}
```

Accedo in questo modo all'indirizzo $p+i$ e $p+i$ potrebbe contenere dati importanti o altro codice

- Posso modificare il return address di una chiamata di una procedura ed eseguire altro codice, posso modificare dei diritti o leggere informazioni riservate
- Tipico "buffer overflow" già visto in Sicurezza e Privacy

type cast e violazione memoria


I puntatori in C sono assimilati a interi

Tramite cast di dati interi a puntatori, posso accedere ad una zona di memoria a piacere

*Programma (OK in compilazione) con conversione da int a char**

```
int main() {  
    char * PTR;  
    PTR = 1000;  
    *PTR = 'a';  
}
```

1000



Deallocazione esplicita e Dangling Pointers

In Pascal, C, ... una locazione puntata da un puntatore p può essere deallocata (liberata) dal programmatore: p è un “dangling pointer”

*Un puntatore è **dangling** se punta ad una zona di memoria che è stata liberata per essere riutilizzata*

- Il sistema operativo potrebbe allocare la stessa memoria nuovamente per memorizzare un altro tipo di valore
- Posso continuare ad usare p per accedere a questa memoria e rompere la type safety

Dangling Pointers sullo stack

Un esempio frequente di errore dovuto a dangling pointers è quando si usano puntatori a celle dello **stack**

Si verifica quando:

- si crea un puntatore p ad una zona A di memoria che è locale ad un metodo (ad esempio variabili locali)
- A è quindi allocata sullo stack
- A viene liberata all'uscita del metodo
- p è a questo punto un dangling pointer

Esempio

Funzione che converte un intero in stringa corrispondente, restituendo il puntatore alla stringa ottenuta:

```
char * itoa(int i){  
    char buf[20];  
    sprintf(buf, "%d", i);  
    return buf;  
}
```

A cosa punta buf ? buf viene restituito ma punta ad un **array locale che viene deallocato**

Esempio in C++

Esempio in C++:

```
struct Point {int x; int y;};
struct Point *newPoint(int x,int y) {
    struct Point result = {x,y};
    return &result;
}
void bar() {
    struct Point *p = newPoint(1,2);
    p -> y = 1234;
}
```

newPoint restituisce un puntatore ad un oggetto (*result*) locale: in bar p è un dangling pointer

Soluzione

Come si possono evitare dangling pointers?

- Evitare di puntare zone di memoria sullo stack ed usare la **malloc**:

```
struct Point * result =  
    (struct Point*)malloc(sizeof(struct Point))
```

La malloc crea puntatori a zone sicure

2. Uso del **garbage collector (gc)** invece che della deallocazione esplicita
 - Il gcc marca lui le zone da liberare e che si possono riutilizzare

Cosa fare per avere evitare tali errori?

Se vogliamo scrivere codice safe cosa possiamo fare?

- Scrivere attentamente, progettare prima, documentare, etc.

Se vogliamo essere sicuri che il nostro codice è safe?

- Due soluzioni possibili
 - usare linguaggi type safe (Java, lisp;..) e linguaggi + astratti
 - usare linguaggi come C e dei tools che ci aiutano a rendere i programmi C safe

In sintesi

- Abbiamo visto alcune fonti di violazioni di sicurezza del C:
 - dereferenziazione non controllata
 - typecast non controllato
 - aritmetica dei puntatori
 - Violazione “spaziale” della memoria, Buffer overflow, ...
 - deallocazione esplicita e dangling pointers
 - Violazione “temporale” della memoria, puntatori allo stack
- Le soluzioni proposte sono:
 - non usare C e passare a Java/C#, ...
 - usare C con tool e librerie che vedremo la prossima lezione



Programmi sicuri in C

Svantaggi ad usare linguaggi astratti

C'è un prezzo da pagare se si vogliono usare linguaggi safe come Java, ...

- **Prestazioni** inferiori
- per il Controllo dei limiti nell'accesso agli array, garbage collection per evitare dangling pointers
- Impiego di maggiore **memoria**
- per tenere informazione sui tipi, sulla dimensione degli array
- **Annotazione** dei tipi
- maggiore verbosità nelle dichiarazioni
- **Porting** di codice già esistente in C
- (per quanto Java abbia sintassi simile al C)

Vantaggi del C

Il C è tutt'oggi usato per molte applicazioni come il sistema operativo, i device drivers

- Ha prestazioni elevate
- Permette la gestione esplicita della memoria
- Permette il controllo della rappresentazione dei dati a basso livello
- Riutilizzo del codice esistente già scritto in C

Alcune violazioni di sicurezza del C

Errori “spaziali” di accesso alla memoria

- Out of bound access, buffer overflow, ...

Errori “temporali” di accesso alla memoria

- Dangling pointers,

Errori di cast

- Tra diversi tipi di puntatori, tra puntatori e dati interi, tipi unione

Memory leaks

- Programmi che non rilasciano la memoria anche quando non serve più

Come rendere il C safe?

1. Tools per l'analisi statica e dinamica per trovare safety violations
 - esempio **Purify** della Rational/IBM è un tool per l'analisi **dinamica** per scoprire errori di accesso alla memoria
2. Librerie per rendere il programmi C safe
3. Tools, e linguaggi per prevenire safety violation con due approcci distinti
 7. rendere sicuri programmi C : SafeC, CCured
 8. varianti safe del C: Cyclone, Vault

Analisi dinamica con Purify

approccio analisi dinamica
input programmi C/C++ (qualsiasi)
output eseguibili linkati con Purify
metodo inserimento di controlli per trovare durante
 l'esecuzione errori di accesso alla memoria o memoria
 non rilasciata
pro si applica a codice già esistente
contro rallenta l'esecuzione e non garantisce la
 scoperta di ogni errore
info [http://www-306.ibm.com/software/awdtools/
purify/](http://www-306.ibm.com/software/awdtools/purify/)
valutazione: ★★ ★

Librerie Safe per le stringhe

Scopo: evitare i buffer overflow e altri problemi tipici delle stringhe e dei buffer di char

1. Safe C String Library

<http://www.zork.org/safestr/>

Autori: Matt Messier e John Viega

2. ISO/IEC TR 24731

Meyers, Randy. Specification for Safer, More Secure C Library Functions, ISO/IEC TR 24731, June 6, 2004

www.open-std.org/jtc1/sc22/wg14/www/docs/n1172.pdf

Supportato da Microsoft

SafeC

approccio traduttore da C a C (C fatto sicuro)
input programmi C (qualsiasi)
output programmi C sicuri
metodo garantisce la cattura delle violazioni di memoria e vari errori run time inserendo dei controlli e aggiungendo informazioni (ad esempio ai puntatori)
pro si applica a C codice già esistente
contro rallenta l'esecuzione e aumenta la memoria necessaria
info <http://www.eecs.umich.edu/~taustin/>
valutazione: ★

CCured

approccio traduttore da C a C (C fatto sicuro)

input programmi C con annotazioni particolari (opzionali)

output programmi C sicuri

metodo abbina analisi statica, controlli dinamici e garbage collector

pro si applica a C codice già esistente con minime modifiche

contro rallenta l'esecuzione

info <http://manju.cs.berkeley.edu/ccured/>

valutazione: ★★

Cyclone

approccio safe C-like language
input programmi C modificati
output programmi C sicuri
metodo controlli dinamici solo dove necessario e garbage collector
pro minimo overhead di tempo e di memoria
contro richiede di modificare i programmi originali
info <http://cyclone.thelanguage.org/>
valutazione: ★ ★ ★

Vault

approccio safe C-like language
input programmi C modificati
output COM objects
metodo linguaggio astratto simile a Java/C#
pro minimo overhead di tempo e di memoria
contro richiede di riscrivere i programmi originali
info <http://research.microsoft.com/vault/>
valutazione: ★★

Confronto sui linguaggi

Controllo sui dettagli a basso livello

- SafeC e CCured: pieno utilizzo del C, operazioni limitate sui puntatori
- Cyclone: più restrittivo del C
- Vault: meno efficiente, più astratto

Opzioni sulla gestione della memoria

- Cyclone: diverse opzioni
- Vault: oggetti “lineari” e regioni
- SafeC: malloc() e free() esplicite
- CCured: garbage collection

Confronto dei costi

Prestazioni

Cyclone \approx Vault $<$ CCured \ll SafeC

Aumento memoria

Cyclone \approx Vault $<$ CCured \ll SafeC

Sforzo per annotare i tipi

SafeC $<$ CCured $<$ Cyclone \approx Vault

Sforzo per portate codice esistente

SafeC $<$ CCured $<$ Cyclone \ll Vault

In sintesi

- Abbiamo visto:
 - quali sono i pro e contro ad usare i linguaggi safe ad alto livello invece che il C
 - possibili modi di rendere il C safe
- Ricordate che:
 - è possibile effettuare l'analisi dinamica con tool come purify
- Per essere certi di avere programmi in C safe abbiamo visto e confrontato questi tool:
 - SafeC, CCured, Cyclone, Vault

