




# MACCHINE ASTRATTE, LINGUAGGI, INTERPRETAZIONE, COMPILAZIONE

1

## MACCHINE ASTRATTE



- una collezione di strutture dati ed algoritmi in grado di **memorizzare** ed **eseguire** programmi
- componenti della macchina astratta
  - interprete
  - memoria (dati e programmi)
  - controllo
  - operazioni "primitive"



2

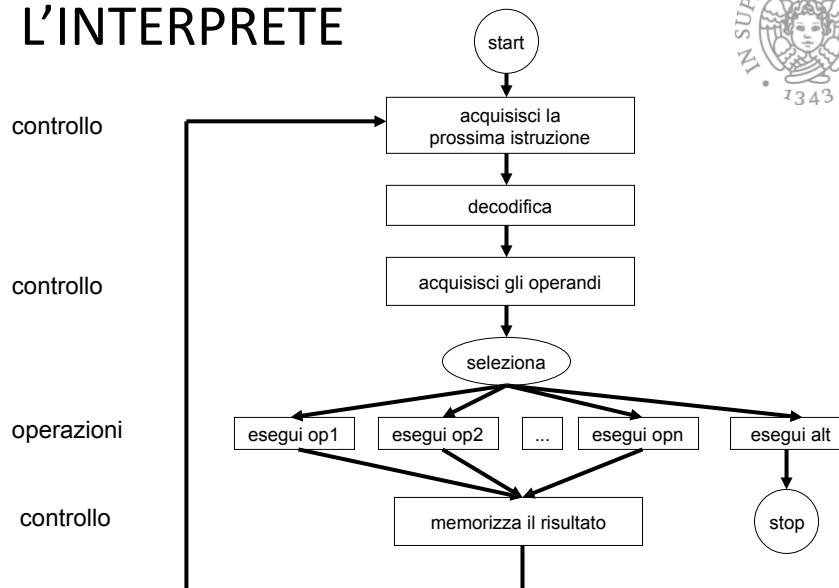
## COMPONENTE DI CONTROLLO



- una collezione di strutture dati ed algoritmi per
  - acquisire la prossima istruzione
  - gestire le chiamate ed i ritorni dai sottoprogrammi
  - acquisire gli operandi e memorizzare i risultati delle operazioni
  - mantenere le associazioni fra nomi e valori denotati
  - gestire dinamicamente la memoria
  - .....

3

## L'INTERPRETE



4

## IL LINGUAGGIO MACCHINA



- ✎ **M** macchina astratta
- ✎ **L<sub>M</sub>** linguaggio macchina di **M**
  - è il linguaggio che ha come stringhe legali tutti i programmi interpretabili dall'interprete di **M**
- ✎ i programmi sono particolari dati su cui opera l'interprete
- ✎ alle componenti di **M** corrispondono componenti di **L<sub>M</sub>**
  - tipi di dato primitivi
  - costrutti di controllo
    - ✓ per controllare l'ordine di esecuzione
    - ✓ per controllare acquisizione e trasferimento dati

5

## MACCHINE ASTRATTE: IMPLEMENTAZIONE



- ✎ **M** macchina astratta
- ✎ i componenti di **M** sono realizzati mediante strutture dati ed algoritmi implementati nel linguaggio macchina di una **macchina ospite M<sub>0</sub>**, già esistente (implementata)
- ✎ è importante la realizzazione dell'interprete di **M**
  - può coincidere con l'interprete di **M<sub>0</sub>**
    - ✓ **M** è realizzata come **estensione** di **M<sub>0</sub>**
    - ✓ altri componenti della macchina possono essere diversi
  - può essere diverso dall'interprete di **M<sub>0</sub>**
    - ✓ **M** è realizzata su **M<sub>0</sub>** in modo **interpretativo**
    - ✓ altri componenti della macchina possono essere uguali

6

## DAL LINGUAGGIO ALLA MACCHINA ASTRATTA



- ✎ **M** macchina astratta       $L_M$  linguaggio macchina di **M**
- ✎ **L** linguaggio                       $M_L$  macchina astratta di **L**
- ✎ implementazione di **L** =  
realizzazione di  $M_L$  su una macchina ospite  $M_O$
- ✎ se **L** è un linguaggio ad alto livello ed  $M_O$  è una macchina “fisica”
  - l’interprete di  $M_L$  è necessariamente diverso dall’interprete di  $M_O$ 
    - ✓  $M_L$  è realizzata su  $M_O$  in modo interpretativo
    - ✓ l’implementazione di **L** si chiama **interprete**
    - ✓ esiste una soluzione alternativa basata su tecniche di traduzione (**compilatore?**)

7


## IMPLEMENTARE UN LINGUAGGIO



- ✎ **L** linguaggio ad alto livello
- ✎  $M_L$  macchina astratta di **L**
- ✎  $M_O$  macchina ospite
- ✎ **interprete (puro)**
  - $M_L$  è realizzata su  $M_O$  in modo interpretativo
  - scarsa efficienza, soprattutto per colpa dell’interprete (ciclo di decodifica)
- ✎ **compilatore (puro)**
  - i programmi di **L** sono tradotti in programmi funzionalmente equivalenti nel linguaggio macchina di  $M_O$
  - i programmi tradotti sono eseguiti direttamente su  $M_O$ 
    - ✓  $M_L$  non viene realizzata
  - il problema è quello della dimensione del codice prodotto
- ✎ due casi limite che nella realtà non esistono quasi mai

8


# LA MACCHINA INTERMEDIA



- ✎ L linguaggio ad alto livello
- ✎  $M_L$  macchina astratta di L
- ✎  $M_I$  macchina intermedia
- ✎  $L_{M_I}$  linguaggio intermedio
- ✎  $M_O$  macchina ospite
- ✎ traduzione dei programmi da L al linguaggio intermedio  $L_{M_I}$  + realizzazione della macchina intermedia  $M_I$  su  $M_O$

9

# INTERPRETAZIONE E TRADUZIONE PURA



- ✎  $M_L = M_I$  interpretazione pura
- ✎  $M_O = M_I$  traduzione pura
  - possibile solo se la differenza fra  $M_O$  e  $M_L$  è molto limitata
    - ✓ L linguaggio assembler di  $M_O$
  - in tutti gli altri casi, c'è sempre una macchina intermedia che estende eventualmente la macchina ospite in alcuni componenti

10

## IL COMPILATORE



- ✎ quando l'interprete della macchina intermedia  $M_I$  coincide con quello della macchina ospite  $M_O$
- ✎ che differenza c'è tra  $M_I$  e  $M_O$ ?
  - il **supporto a tempo di esecuzione (rts)**
    - ✓ collezione di strutture dati e sottoprogrammi che devono essere caricati su  $M_O$  (estensione) per permettere l'esecuzione del codice prodotto dal traduttore (compilatore)
  - $M_I = M_O + rts$
- ✎ il linguaggio  $L_{M_I}$  è il linguaggio macchina di  $M_O$  esteso con chiamate al supporto a tempo di esecuzione

11


## A CHE SERVE IL SUPPORTO A TEMPO DI ESECUZIONE?



- ✎ un esempio da un linguaggio antico (FORTRAN): in linea di principio, è possibile tradurre completamente un programma FORTRAN in un linguaggio macchina puro, senza chiamate al rts, ma ...
  - la traduzione di alcune primitive FORTRAN (per esempio, relative all'ingresso uscita) produrrebbe centinaia di istruzioni in linguaggio macchina
    - ✓ se le inserissimo nel codice compilato, la sua dimensione crescerebbe a dismisura
    - ✓ in alternativa, possiamo inserire nel codice una chiamata ad una routine (indipendente dal particolare programma)
    - ✓ tale routine deve essere caricata su  $M_O$  ed entra a far parte del rts
- ✎ nei veri linguaggi ad alto livello, questa situazione si presenta per quasi tutti i costrutti del linguaggio
  - meccanismi di controllo
  - non solo routines ma anche strutture dati

12


## IL COMPILATORE C



- ✎ il supporto a tempo di esecuzione contiene
  - varie strutture dati
    - ✓ Lo stack
      - ambiente, memoria, sottoprogrammi, ...
    - ✓ la memoria a heap
      - puntatori, ...
  - i sottoprogrammi che realizzano le operazioni necessarie su tali strutture dati
- ✎ il codice prodotto è scritto in linguaggio macchina esteso con chiamate al rts

13

## IMPLEMENTAZIONI MISTE



- ✎ quando l'interprete della macchina intermedia  $M_I$  non coincide con quello della macchina ospite  $M_O$
- ✎ esiste un ciclo di interpretazione del linguaggio intermedio  $L_{M_I}$  realizzato su  $M_O$ 
  - per ottenere un codice tradotto più compatto
  - per facilitare la portabilità su diverse macchine ospiti
  - si deve riimplementare l'interprete del linguaggio intermedio
  - non è necessario riimplementare il traduttore

14

## COMPILATORE O IMPLEMENTAZIONE MISTA?



- ✎ nel compilatore non c'è di mezzo un livello di interpretazione del linguaggio intermedio
  - sorgente di inefficienza
    - ✓ la decodifica di una istruzione nel linguaggio intermedio (e la sua trasformazione nelle azioni semantiche corrispondenti) viene effettuata ogni volta che si incontra l'istruzione
- ✎ se il linguaggio intermedio è progettato bene, il codice prodotto da una implementazione mista ha dimensioni inferiori a quelle del codice prodotto da un compilatore
- ✎ un'implementazione mista è più portabile di un compilatore
- ✎ il supporto a tempo di esecuzione di un compilatore si ritrova quasi uguale nelle strutture dati e routines utilizzate dall'interprete del linguaggio intermedio

15

## L'IMPLEMENTAZIONE DI JAVA



- ✎ è un'implementazione mista
  - traduzione dei programmi da Java a byte-code, linguaggio macchina di una macchina intermedia chiamata Java Virtual Machine
  - i programmi byte-code sono interpretati
  - l'interprete della Java Virtual Machine opera su strutture dati (stack, heap) simili a quelle del rts del compilatore C
    - ✓ la differenza fondamentale è la presenza di una gestione automatica del recupero della memoria a heap (garbage collector)
  - su una tipica macchina ospite, è più semplice realizzare l'interprete di byte-code che l'interprete di Java
    - ✓ byte-code è più "vicino" al tipico linguaggio macchina

15



## TRE FAMIGLIE DI IMPLEMENTAZIONI

- ✎ interprete puro
  - $M_L = M_I$
  - interprete di  $L$  realizzato su  $M_O$
  - alcune implementazioni (vecchie!) di linguaggi logici e funzionali (LISP, PROLOG)
- ✎ Compilatore
  - macchina intermedia  $M_I$  realizzata per estensione sulla macchina ospite  $M_O$  (rts, nessun interprete) (C, C++, PASCAL)
- ✎ implementazione mista
  - traduzione dei programmi da  $L$  a  $L_{M_I}$
  - i programmi  $L_{M_I}$  sono interpretati su  $M_O$ 
    - ✓ Java
    - ✓ i “compilatori” per linguaggi funzionali e logici (LISP, PROLOG, ML)
    - ✓ alcune (vecchie!) implementazioni di Pascal (Pcode)

17

## IMPLEMENTAZIONI MISTE E INTERPRETI PURI

- ✎ la traduzione genera codice in un linguaggio più facile da interpretare su una tipica macchina ospite
- ✎ ma soprattutto può effettuare una volta per tutte (a tempo di traduzione, staticamente) analisi, verifiche e ottimizzazioni che migliorano
  - l'affidabilità dei programmi
  - l'efficienza dell'esecuzione
- ✎ varie proprietà interessate
  - inferenza e controllo dei tipi
  - controllo sull'uso dei nomi e loro risoluzione “statica”
  - ....

18

## ANALISI STATICA



- ✎ dipende dalla semantica del linguaggio
- ✎ certi linguaggi (LISP) non permettono praticamente nessun tipo di analisi statica
  - a causa della regola di scoping dinamico nella gestione dell'ambiente non locale
- ✎ altri linguaggi funzionali più moderni (ML) permettono di inferire e verificare molte proprietà (tipi, nomi, ...) durante la traduzione, permettendo di
  - localizzare errori
  - eliminare controlli a tempo di esecuzione
    - ✓ type-checking dinamico nelle operazioni
  - semplificare certe operazioni a tempo di esecuzione
    - ✓ come trovare il valore denotato da un nome

19

## ANALISI STATICA IN JAVA



- ✎ Java è fortemente tipato
  - il type checking può essere in gran parte effettuato dal traduttore e sparire quindi dal byte-code generato
- ✎ le relazioni di subtyping permettono che una entità abbia un tipo vero (actual type) diverso da quello apparente (apparent type)
  - tipo apparente noto a tempo di traduzione
  - tipo vero noto solo a tempo di esecuzione
  - è garantito che il tipo apparente sia un supertype di quello vero
- ✎ di conseguenza, alcune questioni legate ai tipi possono solo essere risolte a tempo di esecuzione
  - scelta del più specifico fra diversi metodi overloaded
  - casting (tentativo di forzare il tipo apparente ad un suo possibile sottotipo)
  - dispatching dei metodi (scelta del metodo secondo il tipo vero)
- ✎ controlli e simulazioni a tempo di esecuzione

20

# SEMANTICA FORMALE E SUPPORTO A RUN TIME



- ✎ Linguaggi di programmazione:
- ✎ Due aspetti essenziali della nostra visione (intendo quella del corso)
  - semantica formale
    - ✓ eseguibile, implementazione ad altissimo livello
  - implementazioni o macchine astratte
    - ✓ interpreti e supporto a tempo di esecuzione

21

## Perché?



- ✎ perché la semantica formale?
  - definizione precisa del linguaggio indipendente dall'implementazione
    - ✓ il progettista la definisce
    - ✓ l'implementatore la utilizza come specifica
    - ✓ il programmatore la utilizza per ragionare sul significato dei propri programmi
- ✎ perché le macchine astratte?
  - ✓ il progettista deve tener conto delle caratteristiche possibili dell'implementazione
  - ✓ l'implementatore la realizza
  - ✓ il programmatore la deve conoscere per utilizzare al meglio il linguaggio

22

## Perche?



- ✎ **Diventare un programmatore consapevole**
  - Migliore comprensione delle caratteristiche dei linguaggi di programmazione
  - Comprendere le tecniche di implementazione
  - Migliore intuizione del comportamento del proprio codice

23

## Perche'?



- ✎ **Miscela affascinante di teoria e pratica**
  - Applicazione immediata e diretta della teoria
    - ✓ Tecniche di analisi statica: inferenza dei tipi
  - Tecniche algoritmiche (problemi NP-hard)
    - ✓ Allocazione delle risorse a run-time

24


## E IL COMPILATORE?



- ✎ la maggior parte dei corsi e dei libri sui linguaggi si occupano di compilatori
- ✎ perché noi no?
  - il punto di vista dei compilatori verrà mostrato in un corso fondamentale della laurea magistrale
  - delle cose tradizionalmente trattate con il punto di vista del compilatore, poche sono quelle che realmente ci interessano
- ✎ Guardiamo la struttura di un tipico compilatore

25

## Compilatore



### **Front end: fasi di analisi:**


Legge il programma sorgente e determina la sua struttura sia sintattica che semantica

### **Back end: sintesi**

Genera il codice nel linguaggio macchina, programma equivalente al programma sorgente

26

# Compilatore




## Aspetti critici

- Riconoscere i programmi legali (sintatticamente corretti)
- Gestire la struttura dei tipi
- Generare codice compatibile con il SO della macchina ospite

27

## Front End



### Due fasi principali

- Scanner: compito di trasformare il programma sorgente nel lessico (tokens)
- Parser: Legge i token e genera il codice intermedio (IR)

### La teoria aiuta

- La teoria dei linguaggi formali: automi, grammatiche
- Strumenti automatici per generare scanner e parser

# Token



👉 Token: La costituente lessicale del linguaggio

- Operatori & Punteggiatura: {}[]!+-=\*;: ...
- Parole chiaves: if while return class ...
- Identificatori: ....
- Costanti: int, floating-point character, string, ...

# Scanner: un esempio



👉 Input

```
// codice stupido  
if (x >= y) y = 42;
```

👉 Token:

IF	LPAREN	ID(x)	GEQ	ID(y)
RPAREN	ID(y)	BECOMES	INT(42)	SCOLON





## Parser: Output (IR)

- ✎ Formati differenti
- ✎ Formato tipico riconosciuto: albero di sintassi astratta (abstract syntax tree)
  - La struttura sintattica essenziale del programma senza gli aspetti di zucchero sintattico
  - Ne parliamo anche nel seguito



## Parser: AST

- ✎ Abstract Syntax Tree (AST)





## Analisi semantica (statica)



- ☛ Tipicamente dopo la fase di parsing
  - Type checking
  - Uso e allocazione delle risorse
  - Ottimizzazione del codice

## Back End




- ☛ Cosa fa?
  - Traduce il codice intermedio nel linguaggio della macchina ospite
  - Usare le risorse della macchina ospite in modo effettivo



## Il risultato complessivo

Input

```
if (x >= y)
  y = 42;
```



Output

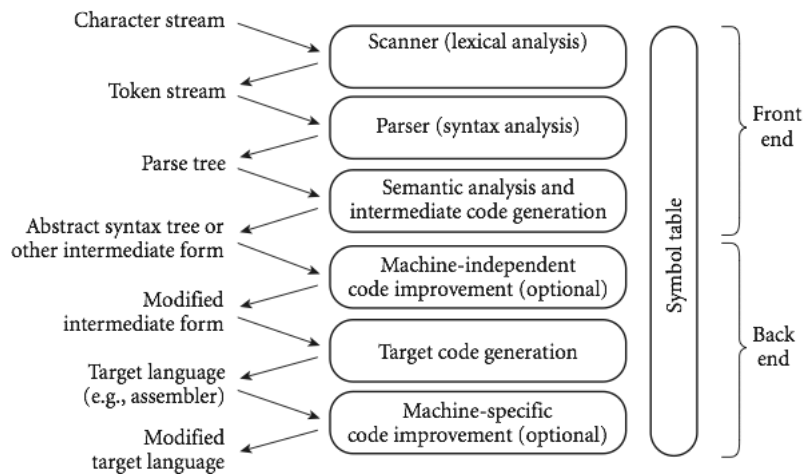
```
mov  eax,[ebp+16]
cmp  eax,[ebp-8]
jl   L17
mov  [ebp-8],42
L17:
```



---

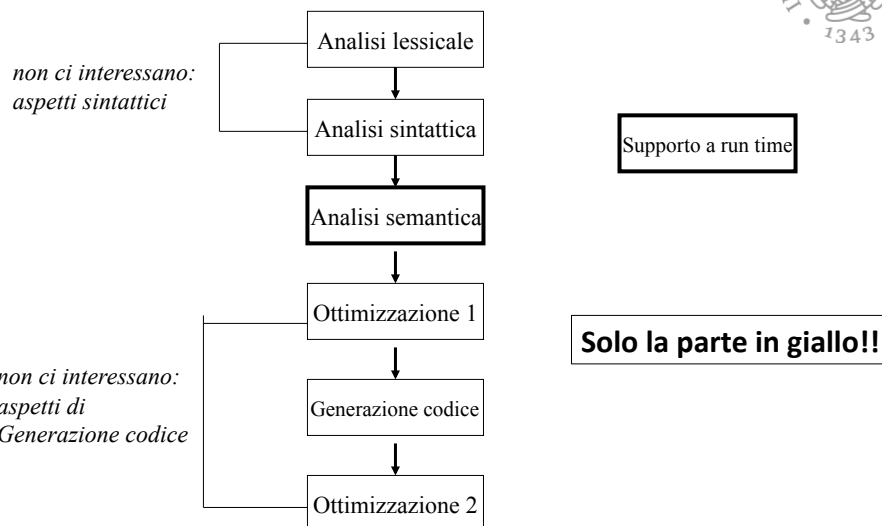
**METTIAMO INSIEME LE COSE**

# Struttura di un compilatore



37

# Cosa ci interessa?



38

# JIT Compiler



- ✎ Idea: compilare il byte code nel codice nativo durante l'esecuzione.
- ✎ Vantaggi:
  - Programma continua a essere portatile;
  - Esecuzioni "ottimizzate" (code inlining)
- ✎ Svantaggi:
  - Run-time system molto complicato; (ottimizzare long-running activations)
  - Costo della compilazioni JIT.
- ✎ Noi non ne parliamo.