

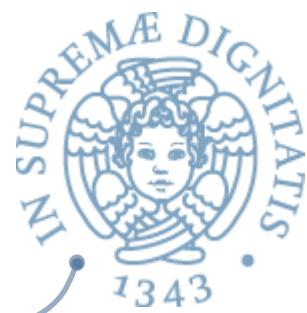
AA 2015-2016

16. Macchine astratte, linguaggi, interpretazione, compilazione

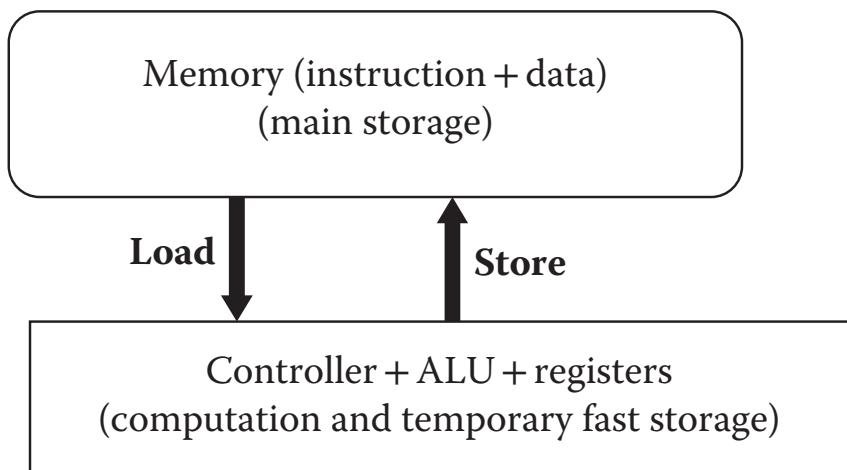


Von Neumann

- ☞ Il modello di **Von Neumann** è alla base della struttura dei computer attuali
- ☞ Due componenti principali
 - **Memoria**, dove sono memorizzati i programmi e i dati
 - **Unità centrale di elaborazione**, che ha il compito di eseguire i programmi immagazzinati in memoria prelevando le istruzioni (e i dati relativi), interpretandole ed eseguendole una dopo l'altra



La macchina di Von Neumann





Ciclo Fetch-Execute

- ☞ **Fetch:** L'istruzione da eseguire viene prelevata dalla memoria e trasferita all'interno della CPU
- ☞ **Decode:** L'istruzione viene interpretata e vengono avviate le azioni interne necessarie per la sua esecuzione
- ☞ **Data Fetch:** Sono prelevati dalla memoria i dati sui quali eseguire l'operazione prevista dalla istruzione
- ☞ **Execute:** È portata a termine l'esecuzione dell'operazione prevista dalla istruzione
- ☞ **Store:** È memorizzato il risultato dell'operazione prevista dalla istruzione

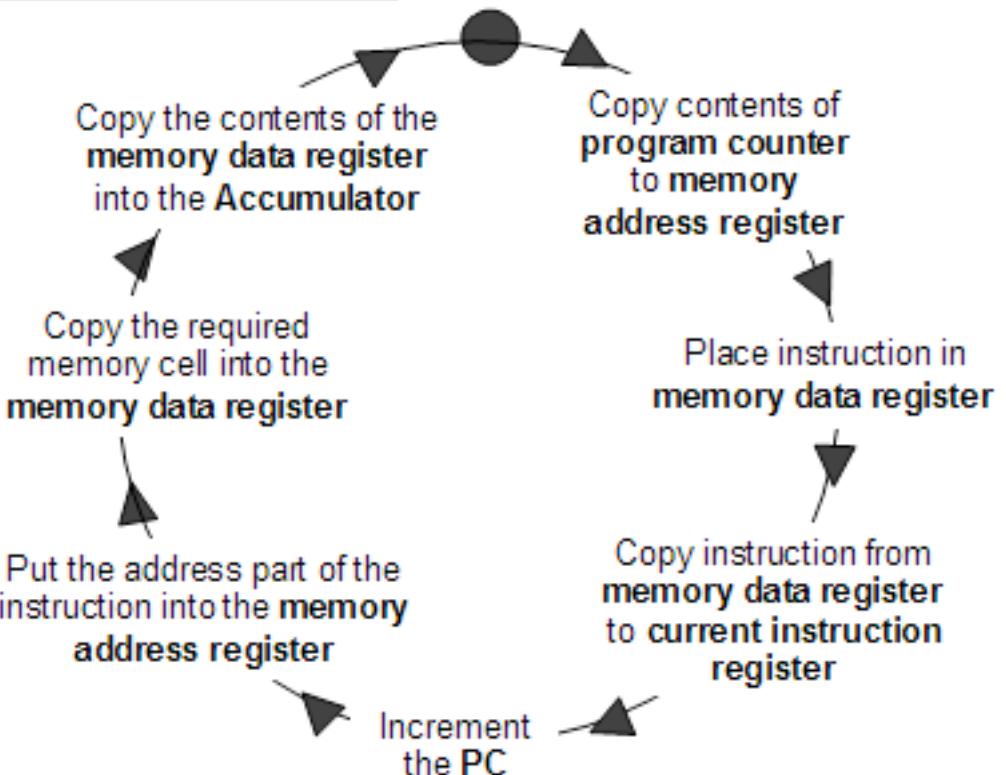


Fetch/Execute Cycle

1. Instruction Fetch (IF)
2. Instruction Decode (ID)
3. Data Fetch (DF)
4. Instruction Execution (EX)
5. Return Result (RR)



A LOAD INSTRUCTION





Il modello di Van Neumann

- ☞ Il modello di Von Neumann fornisce il ***livello di astrazione*** corretto per descrivere l'architettura dei sistemi di elaborazione
- ☞ Nel modello si può descrivere adeguatamente
 - prefetching delle istruzioni
 - parallelismo della CPU
- ☞ **Domanda:** Il modello van Neumann è adeguato per descrivere l'organizzazione concettuale dei linguaggi di programmazione?



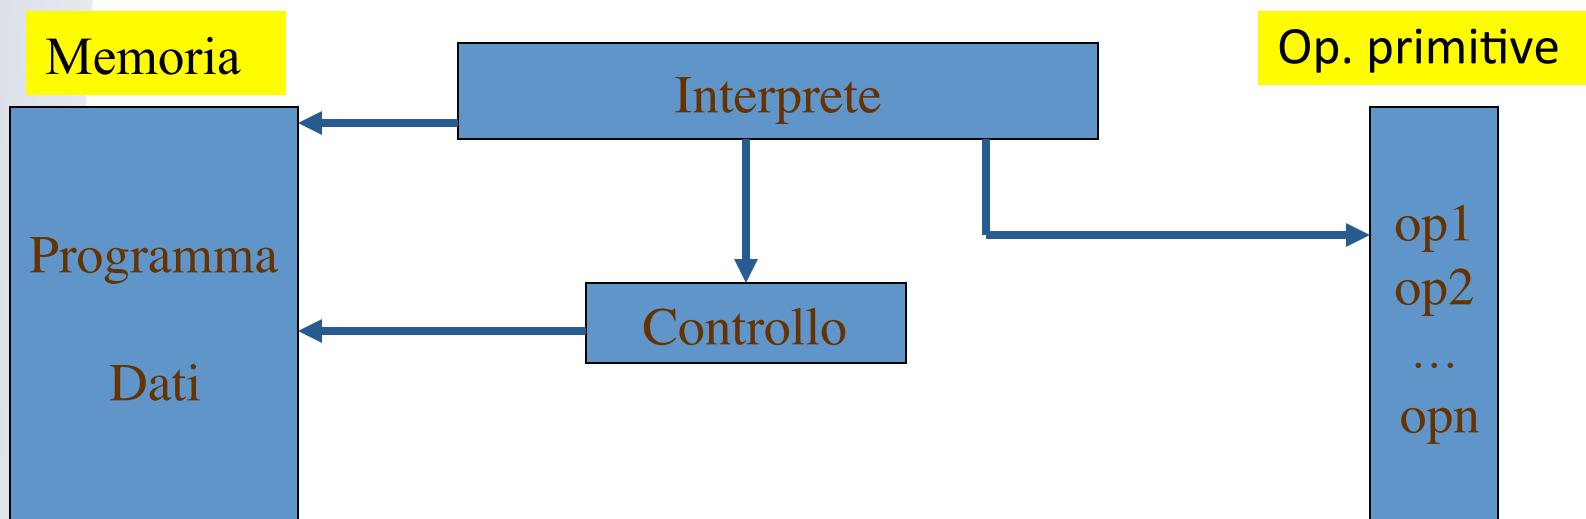
Macchine Astratte

- Macchina Astratta: un **sistema virtuale** che rappresenta il comportamento di una macchina fisica individuando precisamente l'insieme delle risorse necessarie per l'esecuzione di programmi



Macchine astratte

- ☞ Una collezione di strutture dati e algoritmi in grado di **memorizzare** ed **eseguire** programmi
- ☞ Componenti della macchina astratta
 - interprete
 - memoria (dati e programmi)
 - controllo
 - operazioni “primitive”



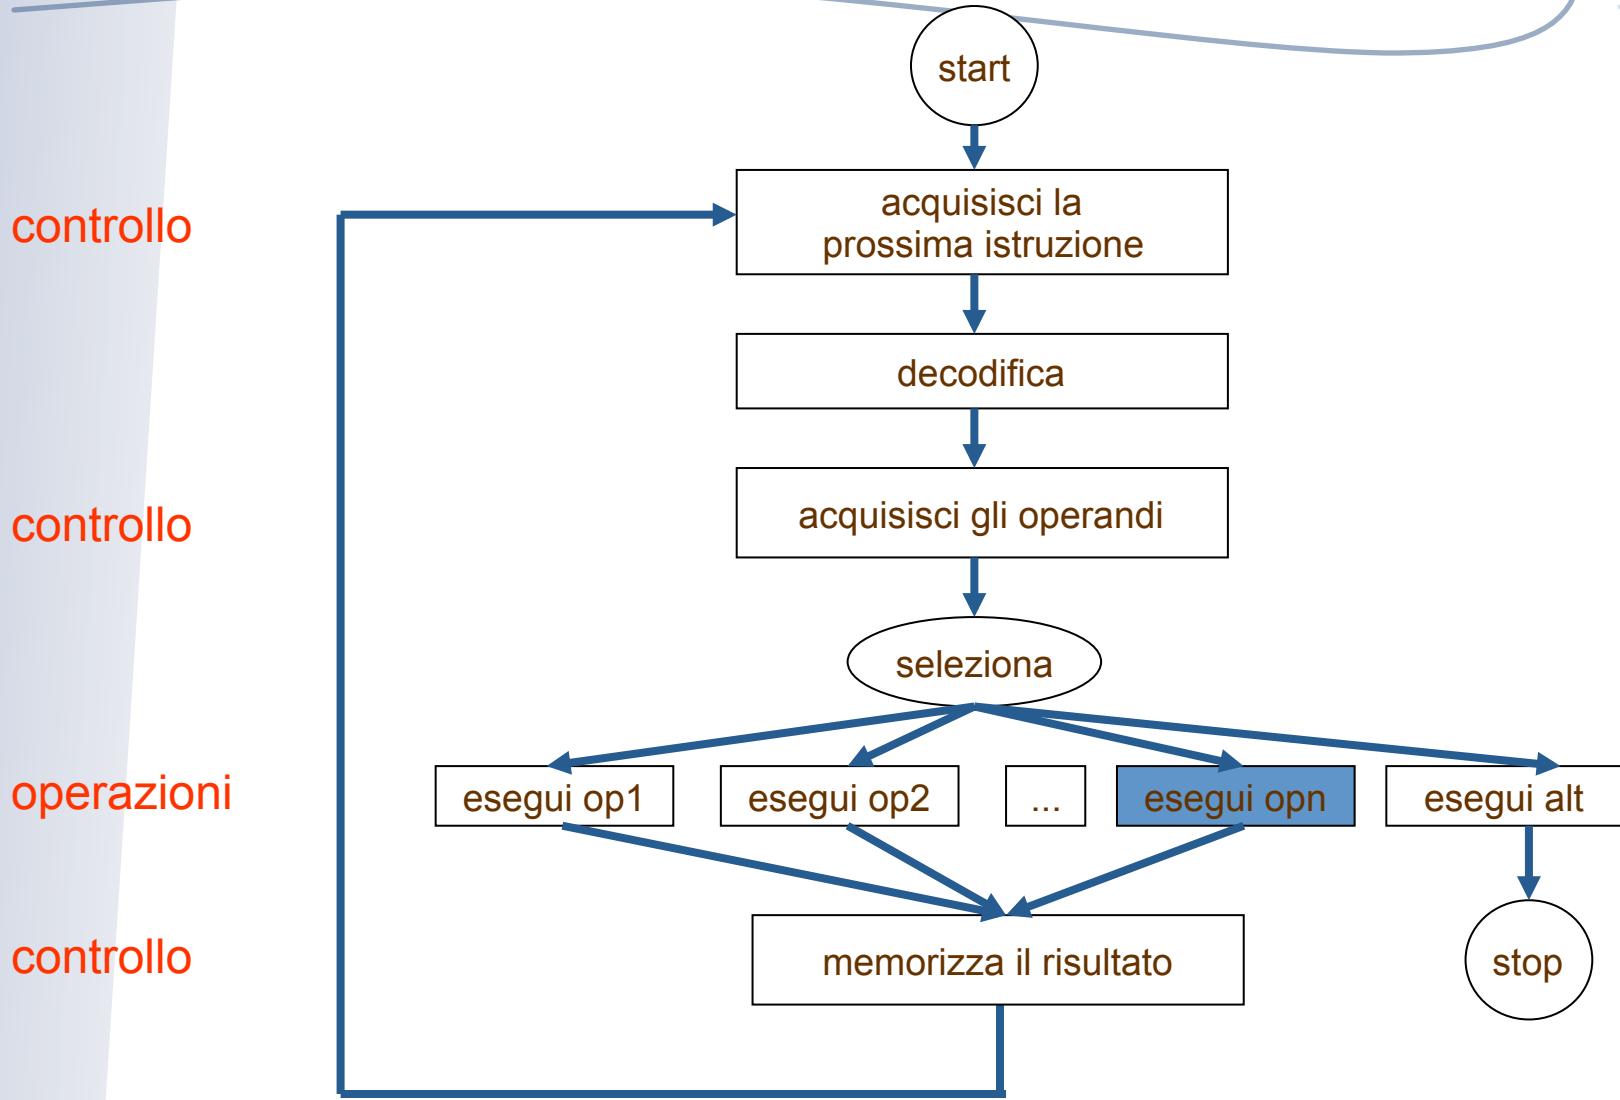


Componente di controllo

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



L'interprete





Il linguaggio macchina

- ☞ **M** macchina astratta
- ☞ **L_M** 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_M**
 - tipi di dato primitivi
 - costrutti di controllo
 - ✓ per controllare l'ordine di esecuzione
 - ✓ per controllare acquisizione e trasferimento dati



Implementare macchine astratte

- ☞ **M** macchina astratta
- ☞ I componenti di **M** sono realizzati mediante strutture dati e algoritmi implementati nel linguaggio macchina di una **macchina ospite M_o** , già esistente (implementata)
- ☞ È importante la realizzazione dell'interprete di **M**
 - può coincidere con l'interprete di **M_o**
 - ✓ **M** è realizzata come **estensione** di **M_o**
 - ✓ altri componenti della macchina possono essere diversi
 - può essere diverso dall'interprete di **M_o**
 - ✓ **M** è realizzata su **M_o** in modo **interpretativo**
 - ✓ altri componenti della macchina possono essere uguali



Da linguaggio a 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 e M_O 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?**)

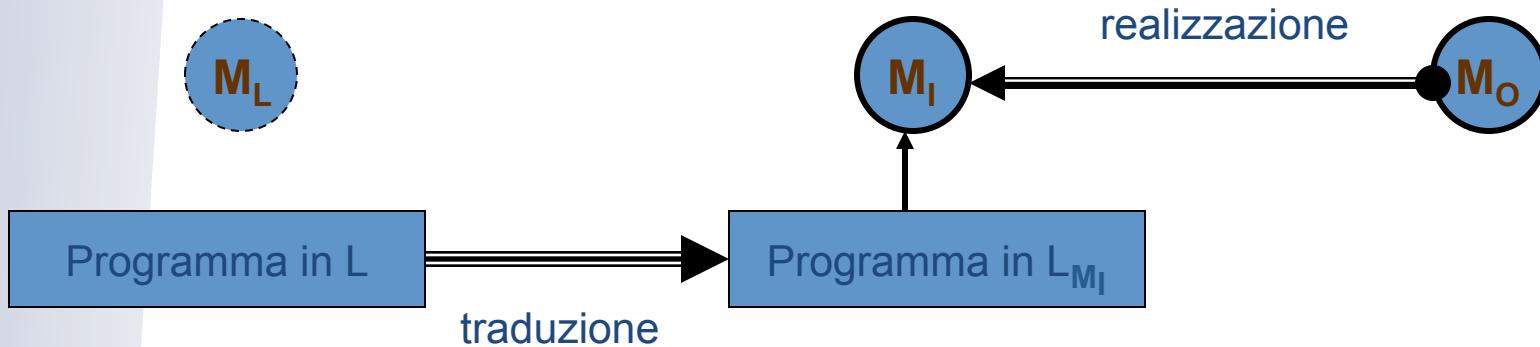


Implementare un linguaggio

- ☞ **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
- ☞ **Casi limite che nella realtà non esistono quasi mai**

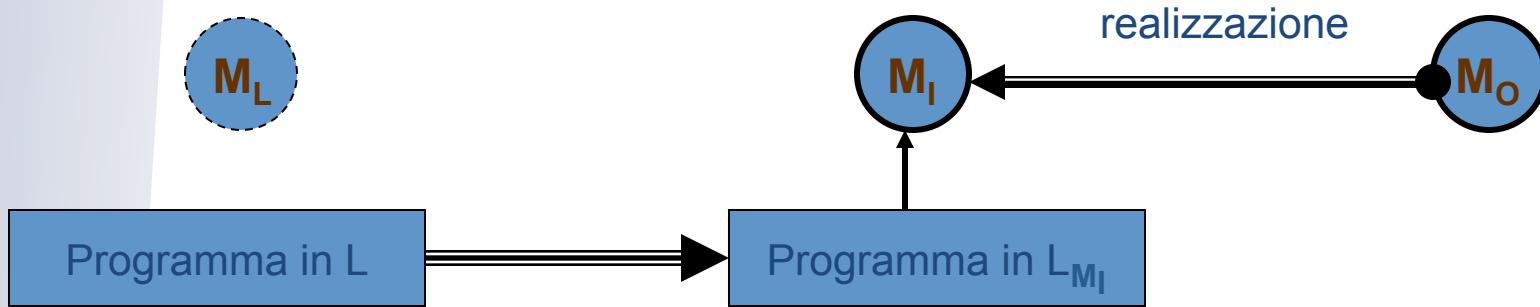


La macchina intermedia



- ☞ **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**

Interpretazione e traduzione pure



- ☞ $M_L = M_I$ 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



Il compilatore

- ☞ Quando l'interprete della macchina intermedia M_I coincide con quello della macchina ospite M_O
- ☞ Che differenza esiste 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)
 - $M_I = M_O + \text{rts}$
- ☞ Il linguaggio L_{M_I} è il linguaggio macchina di M_O esteso con chiamate al supporto a tempo di esecuzione



A cosa serve il rts?

- ☞ Un esempio da un linguaggio antico (**FORTRAN**): in linea di principio è possibile tradurre totalmente 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 a una routine (indipendente dal particolare programma)
 - ✓ tale routine deve essere caricata su **M₀** 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 routine ma anche strutture dati



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



Implementazioni miste

- ☞ Quando l'interprete della macchina intermedia M_I è diverso da 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 più macchine ospiti
 - si deve reimplementare l'interprete del linguaggio intermedio
 - non è necessario reimplementare il traduttore

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 routine utilizzate dall'interprete del linguaggio intermedio

L'implementazione di Java



- ☞ È una 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
 - ✓ il byte-code è più “vicino” al tipico linguaggio macchina

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)

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”
 - ...



Esempi

- ☞ C: compilato in codice macchina (GCC)
- ☞ Java: compilato nel byte-code della JVM (javac) e il byte-code è interpretato dalla JVM (java)
- ☞ JavaScript: interpretato nei browser
- ☞ ...



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
- ☞ 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



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 essere risolte solo a tempo di esecuzione**
 - scelta del più specifico fra diversi metodi overloaded
 - casting (tentativo di forzare il tipo apparente a un suo possibile sottotipo)
 - dispatching dei metodi (scelta del metodo secondo il tipo vero)
- ☞ **Controlli e simulazioni a tempo di esecuzione**



Semantica formale e rts

- ☞ Due aspetti essenziali nella nostra visione (intendendo quella del corso) dei linguaggi di programmazione
 - **semantica formale**
 - ✓ eseguibile, implementazione ad altissimo livello
 - **implementazioni o macchine astratte**
 - ✓ interpreti e supporto a tempo di esecuzione



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



Perché?

- ☞ Diventare un programmatore consapevole
 - migliore comprensione delle caratteristiche dei linguaggi di programmazione
 - comprendere le tecniche di implementazione
 - migliore intuizione sul comportamento del proprio codice



Perché?

- ☞ 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

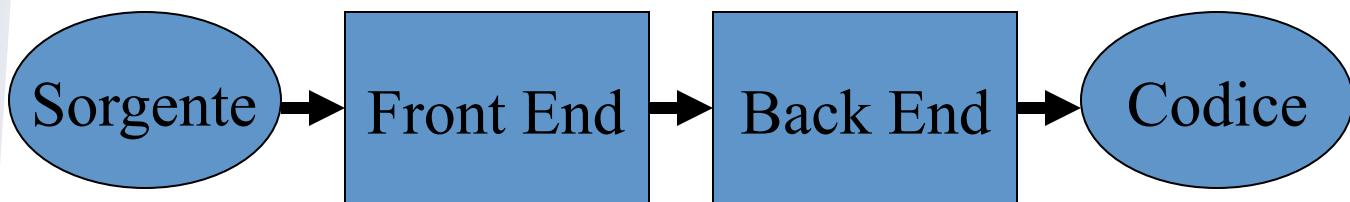


E il compilatore?

- ☞ 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



Compilatore



Front end: fasi di analisi

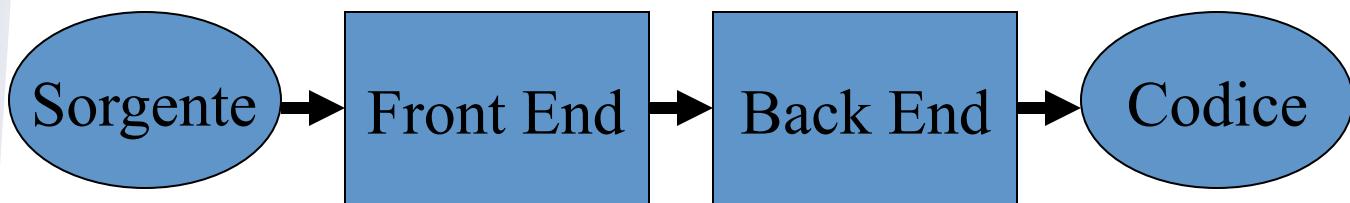
Legge il programma sorgente e determina la sua struttura sia sintattica che semantica

Back end: sintesi

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



Compilatore

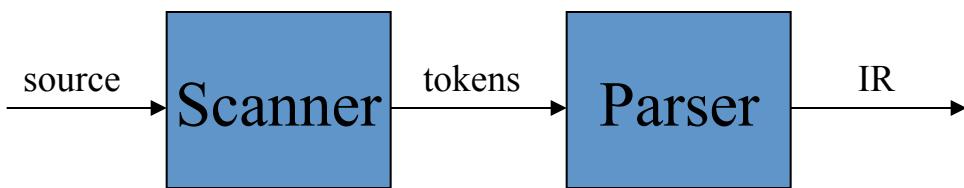


Aspetti critici

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



Front End



- ☞ Due fasi principali
 - scanner: compito di trasformare il programma sorgente nel lessico (token)
 - 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 chiave: if while return class ...
 - identificatori: ...
 - costanti: int, floating-point character, string, ...

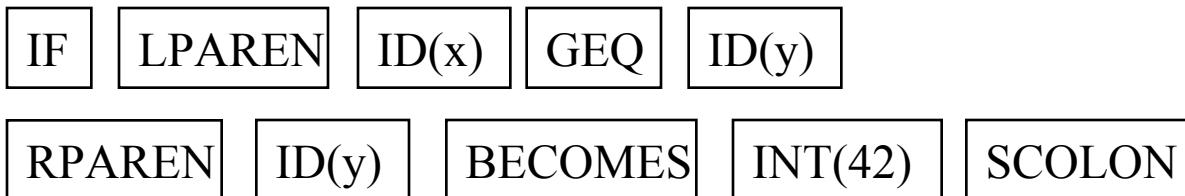


Scanner: un esempio

☞ Input

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

☞ Token





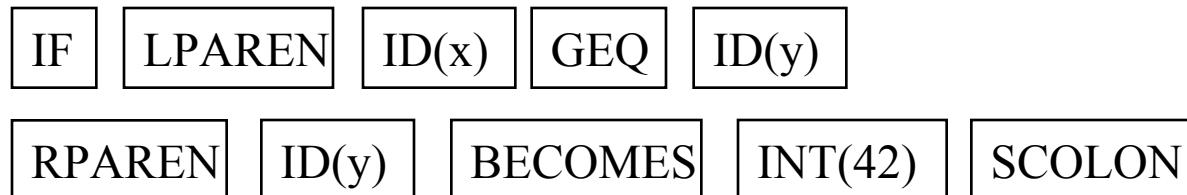
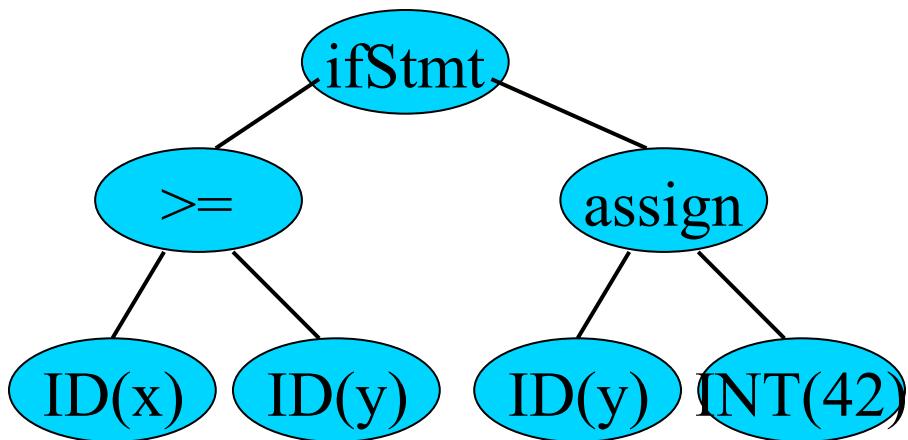
Parser: output (IR)

- ☞ 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)





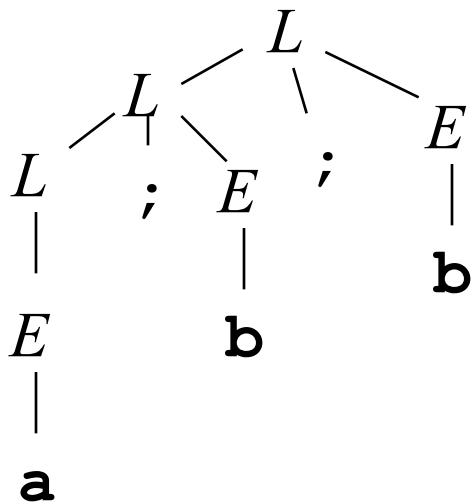
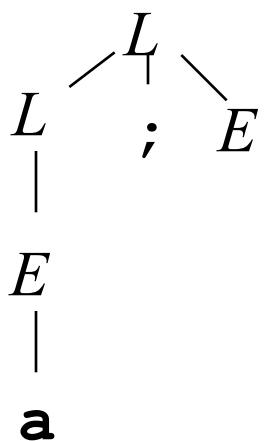
AST

- ☞ Gli alberi di sintassi astratta sono particolarmente rilevanti perché mostrano la struttura semantica significativa dei programmi.
- ☞ Noi nel seguito consideremo sempre la sintassi astratta!!
 - senza considerare gli aspetti di dettaglio quali precedenza operatori, ambiguità, etc.



AST: esempi

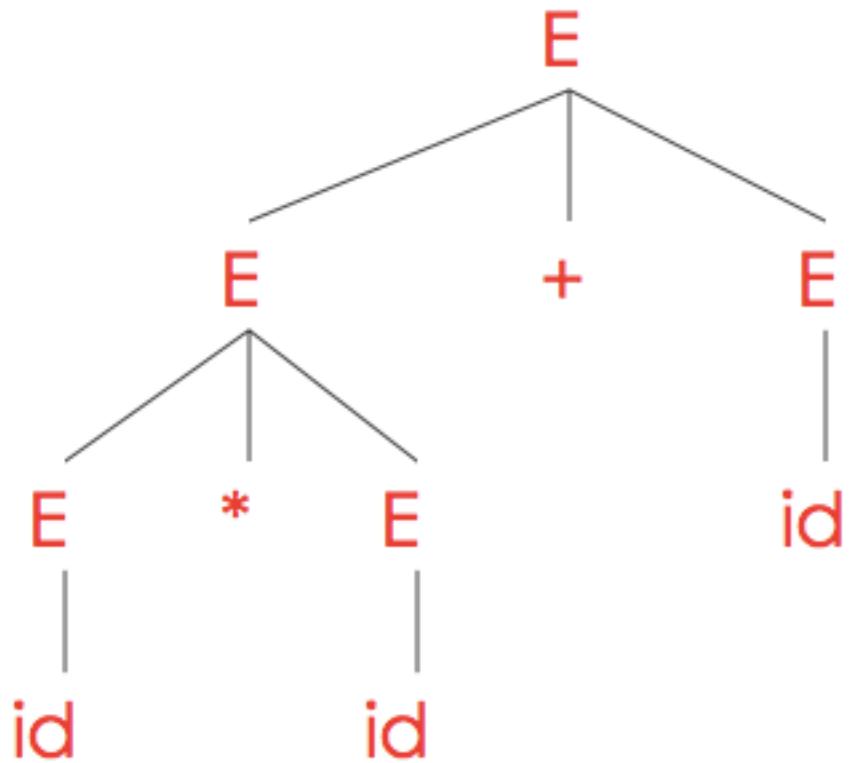
$G: L \rightarrow L ; E \mid E$
 $E \rightarrow a \mid b$





Derivazioni e AST

- E
- E+E
- E * E+E
- id * E + E
- id * id + E
- id * id + id

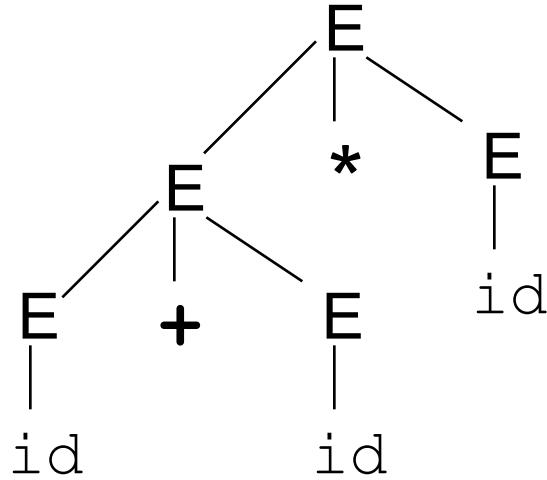
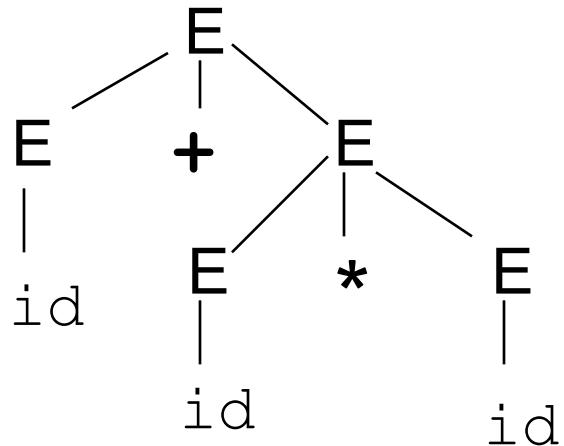




Ambiguità

- ☞ Programma corretto con AST diversi
- ☞ Esempio

- $E \rightarrow E+E \mid E^*E \mid \text{id}$





Come si risolve?

- ☞ Esistono più metodi
- ☞ Ad esempio, codificare nelle regole della grammatica la precedenza degli operatori

$$E \rightarrow E' + E \mid E'$$

$$E' \rightarrow id * E' \mid id \mid (E) * E' \mid (E)$$



Morale

- ☞ La teoria (grammatiche e linguaggi formali) aiuta a strutturare le grammatiche in modo tale da evitare i problemi come quello dell'ambiguità
 - ... e tanti altri ancora
- ☞ Tutte queste problematiche le vedrete nella magistrale...



Sintassi astratta

- ☞ La sintassi astratta di un linguaggio è espressa facilmente coi **tipi di dato algebrici** di Ocaml
 - ogni categoria sintattica diventa un tipo di dato algebrico di Ocaml

BNF

BoolExp =

- | True
- | False
- | NOT BoolExp
- | BoolExp AND BoolExp

Algebraic Data Type

Type BoolExp =

- | True
- | False
- | Not of BoolExp
- | And of BoolExp * BoolExp



Esempio

Nome. Produzione grammaticale

EAdd.	Exp	::=	Exp	"+"	Exp1	;
ESub.	Exp	::=	Exp	"-"	Exp1	;
EMul.	Exp1	::=	Exp1	"*"	Exp2	;
EDiv.	Exp1	::=	Exp1	"/"	Exp2	;
EInt.	Exp2	::=	Integer	;		

```
type exp =
    EAdd of exp * exp
  | ESub of exp * exp
  | EMul of exp * exp
  | EDiv of exp * exp
  | EInt of int
```



AST in Java

- ☞ Potremmo codificare la sintassi astratta di un linguaggio anche in Java
- ☞ In che modo?
 - ogni categoria sintattica è una classe astratta
 - ogni costruttore sintattico è una sottoclassa che estende la classe astratta



AST in Java (esempio)

- ☞ public abstract class Exp { ... }

- ☞ public class ESub extends Exp {
 public final Exp exp_1, exp_2;
 public ESub(Exp p1, Exp p2) {
 exp_1 = p1; exp_2 = p2;
 }
 :
}



Analisi semantica (statica)

- ☞ Tipicamente dopo la fase di parsing
 - type checking
 - uso e allocazione delle risorse
 - ottimizzazione del codice



Back End

☞ Cosa fa?

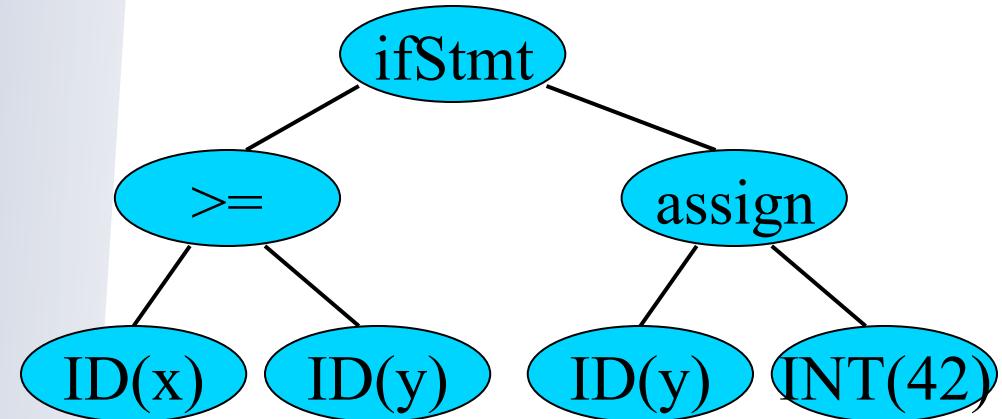
- traduce il codice intermedio nel linguaggio della macchina ospite
- usa le risorse della macchina ospite in modo effettivo



Il risultato complessivo

☞ Input

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



☞ Output

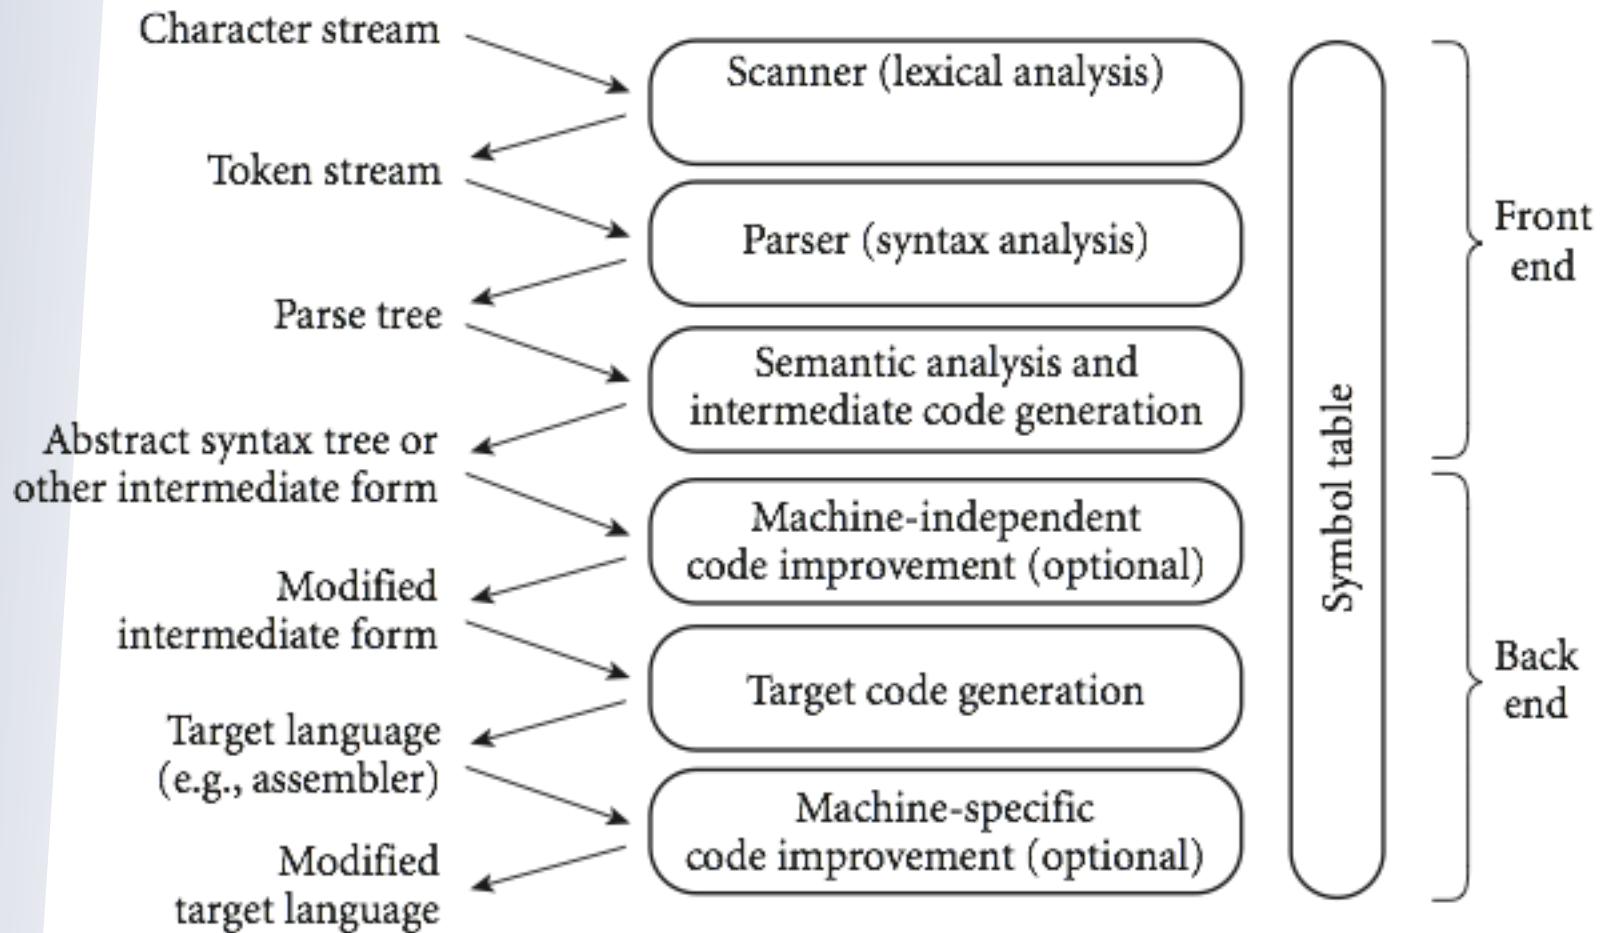
```
mov eax,[ebp+16]  
cmp eax,[ebp-8]  
jl L17  
mov [ebp-8],42  
L17:
```



Mettiamo insieme le cose



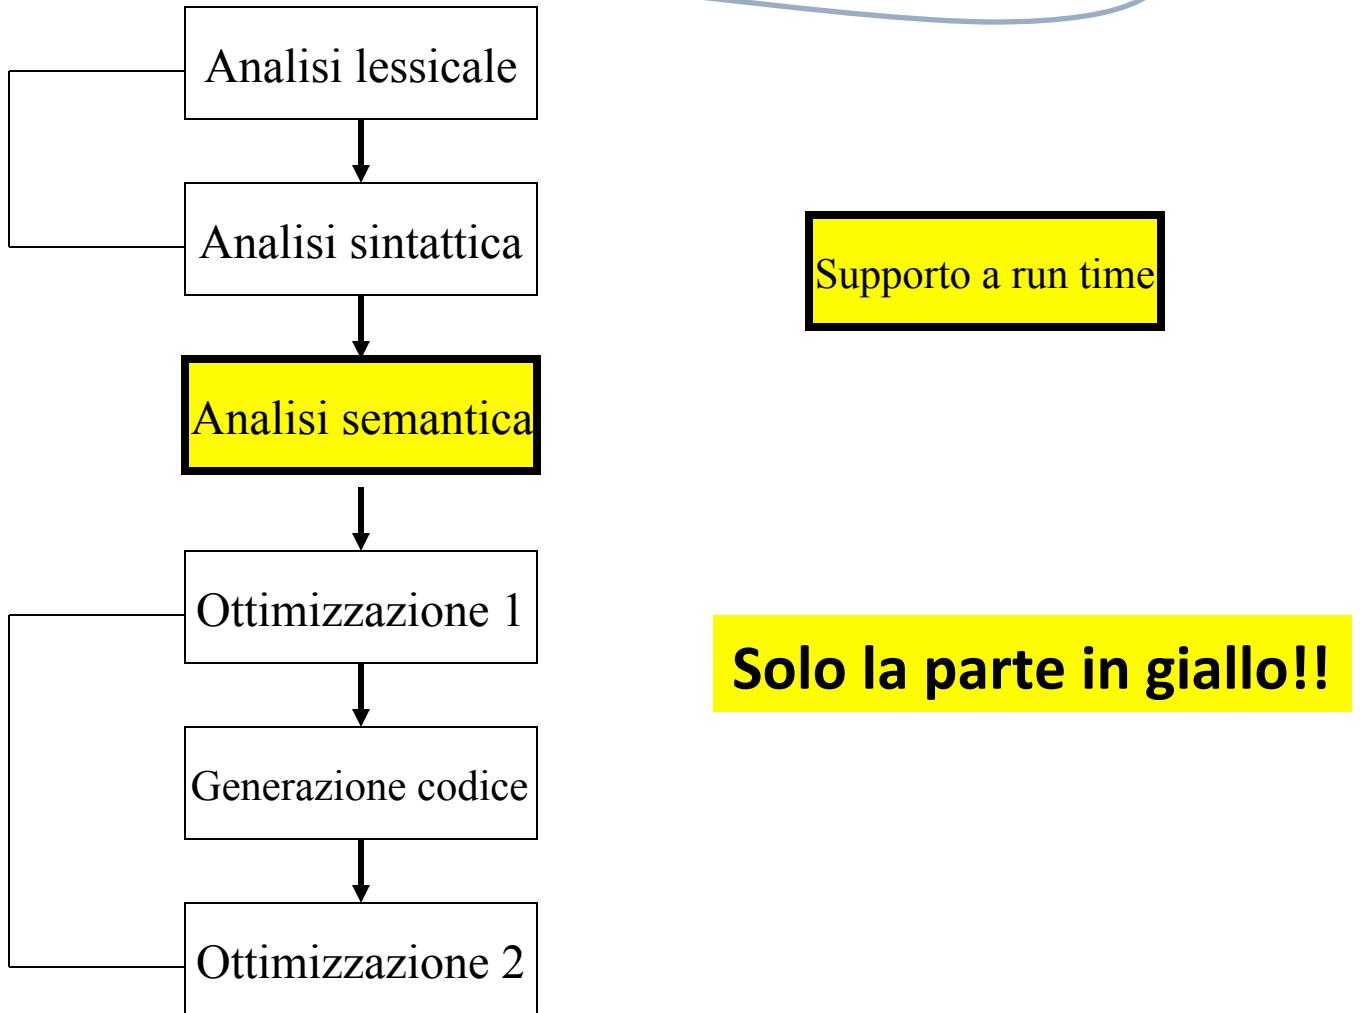
Struttura di un compilatore





Cosa ci interessa?

*non ci interessano:
aspetti sintattici*



*non ci interessano:
aspetti di generazione
codice*



JIT compiler

- ☞ Idea: compilare il byte-code nel codice nativo durante l'esecuzione
- ☞ Vantaggi
 - programma continua a essere portatile;
 - esecuzioni “ottimizzate” (code inlining)
- ☞ Svantaggi
 - rts molto complesso (ottimizza long-running activation)
 - costo della compilazioni JIT
- ☞ Noi non ne parliamo!