# Automi e Linguaggi Formali

## Struttura di un compilatore e fasi principali

01 Ottobre 2014

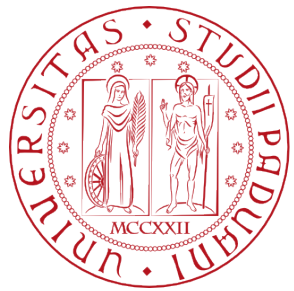


Università degli Studi di Padova

A.A. 2014-2015
Enrico Mezzetti
*emezzett@math.unipd.it*

# Linguaggi di programmazione

- **Linguaggio di programmazione** e' un formalismo per descrivere calcoli e computazioni (i.e., programmi)
- **Programma**, per essere eseguito, deve essere tradotto in una forma che puo' essere capita da un calcolatore $\Rightarrow$ compilatore
- Principi e tecniche per il riconoscimento/comprensione dei linguaggi utilizzate nella progettazione di compilatori
  - Ricorrenti in molte altre aree dell'informatica
    - linguaggi di programmazione
    - architettura
    - teoria dei linguaggi
    - algoritmi
    - ingegneria del software
    - ...

# Categorie di compilatori

- **Compilatore**: traduttore di programmi

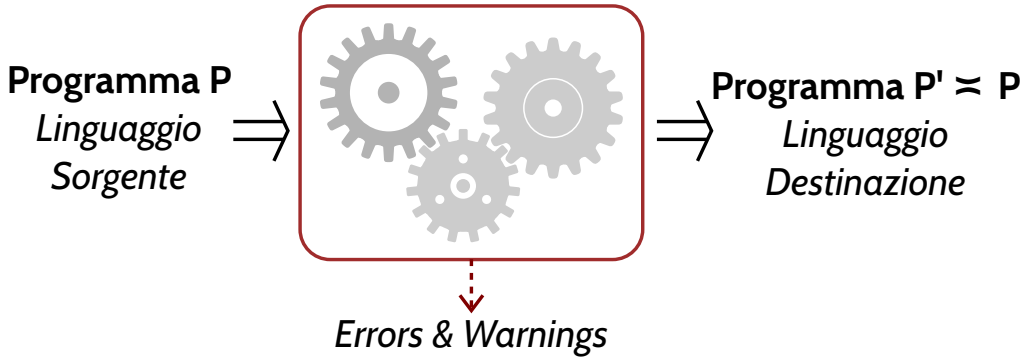


  - Cattura gli errori identificati durante la traduzione
  - Se **P'** e' *eseguibile* allora

$$input \rightarrow \boxed{\mathbf{P'}} \rightarrow output$$

- **Interprete**: esecutore diretto di programmi

$$\begin{matrix} sorgente \rightarrow \\ input \rightarrow \end{matrix} \boxed{\textbf{Interprete}} \rightarrow output$$

  - Generalmente piu' lento
  - Soluzioni *ibride*

# Ruolo effettivo dei compilatori

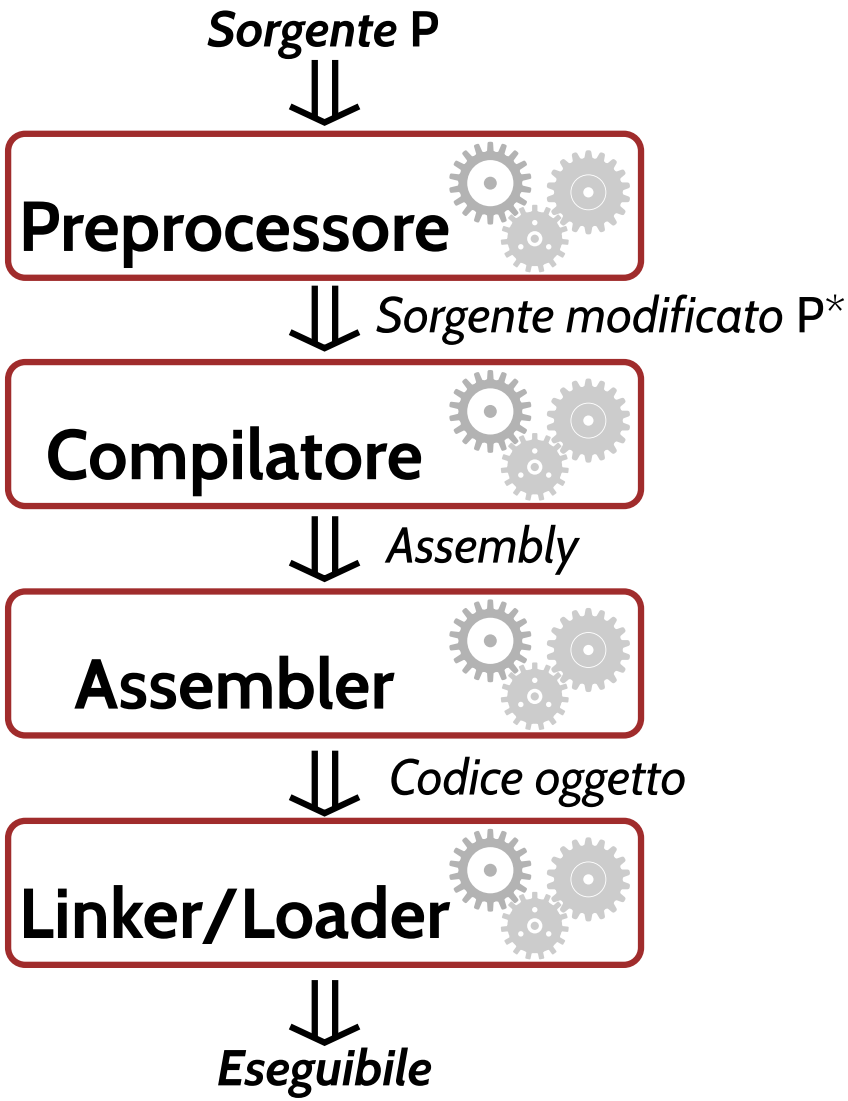

# Struttura di un compilatore

## Front-end (Analisi)

- Identifca elementi base del *programma sorgente* e li inserisce in una struttura grammaticale;
- Crea una rappresentazione intermedia del programma sorgente;
- Segnala possibili errori
- Genera *tavola dei simboli* e applica ottimizzazioni

## Back-end (Sintesi)

- Costruisce il *programma destinazione* partendo da rappresentazione intermedia e tavola dei simboli, applicando ulteriori ottimizzazioni

- **Sequenza di fasi**: analisi lessicale, analisi sintattica, analisi semantica, generazione del codice intermedio, ottimizzazionee del codice, generazione del codice

# Analisi lessicale (scanning)

- Legge programma sorgente come flusso di caratteri
  - Identifica sequenze complete e significative (**lexemi**)
- Per ogni lexema genera un **token**

$$< \text{nome-token}[,\text{valore-attributo}] >$$

*simbolo astratto* ↑ ↑ *posizione nella symbol table*

- Esempio: `posizione` = `iniziale` + `velocita'` * 60
  - `posizione` ⇒ <id,1> (posiz. 1 in symbol table)
  - `=` ⇒ <=> (no valore-attributo)
  - `iniziale` ⇒ <id,2>
  - `+` ⇒ <+>
  - `velocita'` ⇒ <id,3>
  - `*` ⇒ <*>
  - 60 ⇒ <60>
  - <id,1> <=> <id,2> <+> <id,3> <*> <60>
- Approcci: **linguaggi regolari**, **automi a stati finiti**, **espressioni regolari**

# Analisi sintattica (parsing)

- Opera sull'output dell'analisi lessicale (insieme di token)
- *Parser* genera un rappresentazione intermedia ad albero
  - Indica la struttura grammaticale della sequenza di token
- **Albero sintattico**
  - Nodo interno = operazione, figli = operandi
  - Indica l'ordine in cui eseguire le operazioni (precedenza tra operatori)
- Approcci: **grammatiche libere da contesto**, **automi a pila**, **linguaggi liberi da contesto**

# Analisi sintattica (parsing) - 2

- Esempio di costruzione

<id,1> <=> <id,2> <+> <id,3> <*> <6>

(posizione = iniziale + velocita′ ∗ 60)

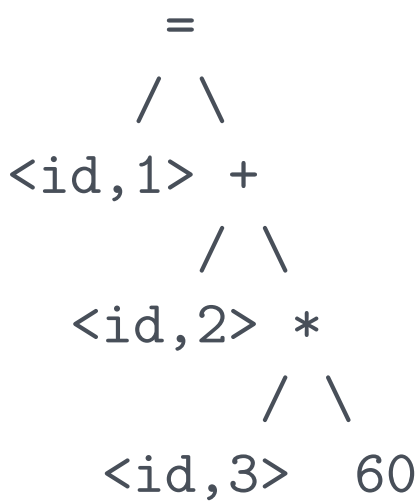


- Costruzione bottom-up:
  1. Moltiplicare il lexema di <id,3> (velocita') con 60
  2. Sommare il risultato con il valore di iniziale
  3. Memorizzare il risultato nella locazione posizione

# Analisi semantica

- Opera sull'output delle fasi precedenti (tabella e albero)
  - Controllo della *consistenza semantica* del programma (rispetto alla definizione del linguaggio)
  - Colleziona informazioni sui tipi e le mette nella tavola dei simboli (per la fase di generazione del codice)
- **Type checking** (controllo dei tipi):
  - Tipi degli operandi devono essere consistente con quelli attesi dall'operatore
  - E.g., un indice di un array deve essere un intero (errore se ad esempio floating-point)
- **Coercion** (conversione forzosa)
  - Se un'operando si applica a piu' tipi (e.g., `int` o `float`)
  - se un operando e' `int` e l'altro e' `float` applichiamo una conversione a `float`

# Analisi semantica - 2

- Esempio di Coercion
  - `posizione`, `iniziale`, e `velocita'` sono dichiarati `float`
  - 60, invece, e' un `int`
  - Pperazione $*$ richiede una coercion

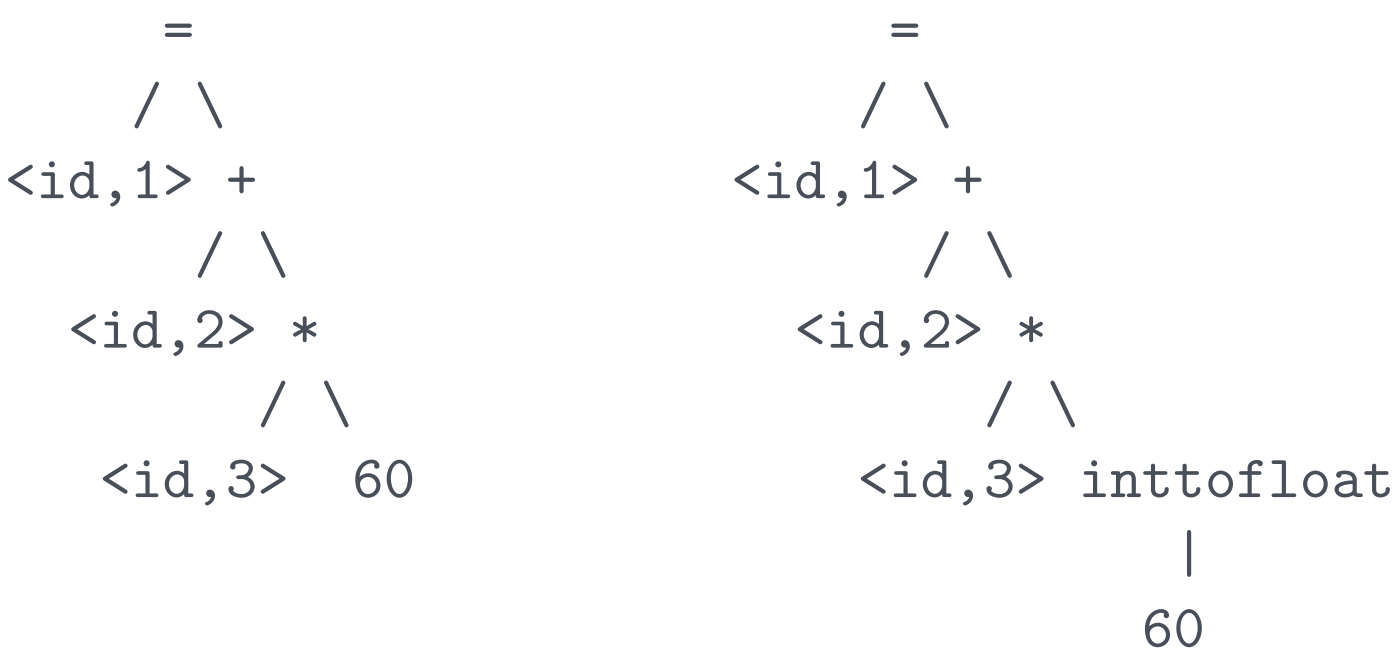

# Generazione del codice intermedio

- Rappresentazioni intermedie di basso livello
  - Semplici e facili da tradurre in codice macchina
- Tipico esempio **codice a tre indirizzi** (*three-address code*)
  - Istruzioni simili all'assembly con tre operandi per istruzione
- Nel solito esempio otterremmo:

```
t1 = inttofloat(60)
t2 = id3 * t1
t3 = id2 + t2
id1 = t3
```

- Proprieta'
  - Al piu' un operatore sulla destra $\rightarrow$ le istruzioni danno l'ordine in cui effettuare le operazioni ($* \prec +$)
  - Un nome temporaneo generato per contenere il valore calcolato da ogni istruzione ($\sim$registri virtuali)

# Ottimizzazione del codice

- Miglioramento del codice intermedio in funzione di un migliore codice oggetto
  - Piu' veloce, piu' piccolo, meno energia necessaria, ecc.
- Esempio:

```
t1 = inttofloat(60)
t2 = id3 * t1
t3 = id2 + t2
id1 = t3
```

*Diventa* $\longrightarrow$

```
t1 = id3 * 60.0
id1 = id2 + t1
```

opt1 Conversione da integer a floating-point fatta a tempo di compilazione (e non a tempo di esecuzione), e quindi eliminata dal codice

opt2 `t3` era usato solo per trasmettere un valore ad `id1`

# Generazione del codice

- Da rappresentazione intermedia a codice oggetto
- Registri o locazioni di memoria per ogni variabile del codice
- Da ogni istruzione in codice intermedio a sequenza di istruzioni in codice macchina

Esempio:

```
t1 = id3 * 60.0
id1 = id2 + t1
```

*Diventa* $\longrightarrow$

```
LDF R2, id3
MULF R2, R2, #60.0
LDF R1, id2
ADDF R1, R1, R2
STF id1, R1
```

gen1 Il primo operando specifica una destinazione, `F`: floating-point

gen2 id3 in R2, poi moltiplicazione con 60.0 e risultato in R2, poi id2 in R1, poi somma di R1 e R2 in R1, poi R1 in id1

# Strumenti per la costruzione di un compilatore

- **Generatori di parser**: generano automaticamente un parser dalla descrizione della grammatica di un linguaggio
- **Generatori di scanner**: generano automaticamente un analizzatore lessicale dalla descrizione tramite espressioni regolari dei token di un linguaggio
- **Generatori di generatori di codic**e: da regole per tradurre ogni operazione in una sequenza di istruzioni in linguaggio macchina

# Ruolo dell'analisi lessicale

- Prima fase del processo di compilazione
  - Legge i caratteri del programma e li raggruppa in *lexemi*,
  - Per ogni lexema produce un *token* $\rightarrow$ Parser
  - Lexemi che rappresentano indentificatori vanno nella tabella dei simboli
- Altre operazioni ausliarie
  - Elimina spazi bianchi e commenti, mantiene le corrispondenze con i file sorgenti, espande le macro, ...
- Due fasi effettive
  - Scanning ▶ compattazione della stringa di caratteri
  - Analisi lessicale ▶ estrazione tokens da lexemi
- Diagramma o altro modo di descrivere i lexemi di ogni token
  - Useremo **automi a stati finiti** e **espressioni regolari** (dimostreremo sono equivalenti)

# Token, pattern, lexemi

- **Token**: coppia <nome token, valore attributo>
  - nome token: simbolo astratto che rappresenta un'unita' lessicale (parola chiave, identificatore, ecc.)
- **Pattern**: descrizione della forma che i lexemi di un token possono avere
  - Token parola-chiave $\Rightarrow$ il pattern e' la sequenza di caratteri che formano la parola chiave
  - Token identificatore $\Rightarrow$ il pattern e' pi complesso e pu corrispondere a piu' stringhe di caratteri
- **Lexema**: sequenza di caratteri del programma sorgente che rispetta il pattern di un token
- Esempi:

| Token | Pattern | Matching lexemes |
|---|---|---|
| **if** | caratteri i e f | `if` |
| **id** | caratteres seguito da altri caratteri e/o cifre | `posizione`, `iniziale` |
| **number** | numero | 3.14159, 0, 6.2 |

# Classi tipiche di token

- Classi di token (dipendono dal linguaggio)
  - *Keywords*: un token per ogni parola chiave
  - *Operators*: vari token per gli operatori
  - *Identifers*: un token per tutti gli identificatori
  - *Constants*: vari token per le costanti (numeri, letterali, ecc.)
  - *Punctuation*: per altri simboli (parentesi, virola, ecc.)
- **Nome token** $\rightarrow$ quale tipo di token
- **Valore-attributo** $\rightarrow$ identifica uno specifico lexema come istanza del token
  - Piu' attributi necessari $\blacktriangleright$ puntatore a tabella dei simboli

# Esempio

- Comando Fortran `E = M * C ** 2`
- Token generati:
  <id, puntatore ad E nella tavola dei simboli>
  <assign-op>
  <id, puntatore ad M nella tavola dei simboli>
  <mult-op>
  <id, puntatore a C nella tavola dei simboli>
  <exp-op>
  <number, valore intero 2>

- Non e' sempre banale riconoscere i lexemi (ambiguita')

# Input buffering

- Esempio: per sapere di essere alla fine di un identificatore, dobbiamo almeno leggere un carattere che non e' ne' una lettera ne' una cifra
- Esempio (C): $<$ potrebbe essere un operatore oppure l'inizio di $<=$
- Esempio (Fortran 90, spazi sono irrilevanti):

  `DO 5 I = 1.25` vs. `DO 5 I = 1,25`

  - DO5I=1.25 $\rightarrow$ simple assignment
  - DO 5 I=1, 25 $\rightarrow$ repeat line 5, 25 times using I as a counter

  il primo lexema e' la parola chiave DO (comando for)
- Spesso e' necessario leggere oltre la fine di un lexema per intercettarlo
- Due puntatori per scorrere l'input: uno all'inizio del lexema corrente, uno per leggere oltre, finche' non si trova un lexema

# Specifica dei token

- Metodi formali per la specifica dei token
  - Linguaggi regolari
  - Espressioni regolari per descrivere i token
  - Automi a stati finiti per descrivere analizzatori lessicali
  - passaggio da espressione regolare ad automa