Interpreti, compilatori e semantica operazionale

Linguaggi di programmazione

- Come si comprendono le caratteristiche di un linguaggio di programmazione?
- Molte risposte diverse…
  - manuali, documentazione on-line, esempi, consultazione `stackoverflow`.com, …
- La nostra risposta
  - la comprensione di un linguaggio di programmazione si ottiene dalla **semantica** del linguaggio
- Semantica come guida alla progettazione, all'implementazione e all'uso di un linguaggio di programmazione

Elementi di semantica operazionale

Sintassi e semantica

- Un linguaggio di programmazione possiede
  - una **sintassi**, che definisce
    - le "formule ben formate" del linguaggio, cioè i programmi sintatticamente corretti, tipicamente generati da una grammatica
  - una **semantica**, che fornisce
    - un'interpretazione dei "token" in termini di entità (matematiche) note
    - un significato ai programmi sintatticamente corretti
- La **teoria dei linguaggi formali** fornisce formalismi di specifica (grammatiche) e tecniche di analisi (automi) per trattare aspetti sintattici
- Per la semantica esistono diversi approcci
  - **denotazionale, operazionale, assiomatica, …**
- La semantica formale viene di solito definita su una rappresentazione dei programmi in **sintassi astratta**

Sintassi concreta

- La **sintassi concreta** di un linguaggio di programmazione è definita di solito da una **grammatica libera da contesto** (come visto a **PR1**)
- ***Esempio***: grammatica di semplici **espressioni logiche** (in Backus-Naur Form, BNF)
  - **e ::= v | Not e | (e And e)| (e Or e) | (e Implies e)**
  - **v ::= True | False**
- Notazione comoda per programmatori (operatori infissi, associatività-commutatività di operatori, precedenze)
- Meno comoda per una gestione computazionale (si pensi a problemi di ambiguità)

Sintassi astratta

- L'**albero sintattico** (***abstract syntax tree***) di un'espressione **exp** mostra (risolvendo le ambiguità) come **exp** può essere generata dalla grammatica
- La **sintassi astratta** è una rappresentazione lineare dell'albero sintattico
  - gli operatori sono nodi dell'albero e gli operandi sono rappresentati dai sottoalberi
- Per gli AST abbiamo quindi sia una notazione lineare che una rappresentazione grafica

Dalla sintassi concreta all'AST

(True And False) Implies ((Not True) And False)

SINTASSI CONCRETA

Implies(And(True,False), And(Not(True),False))

SINTASSI ASTRATTA

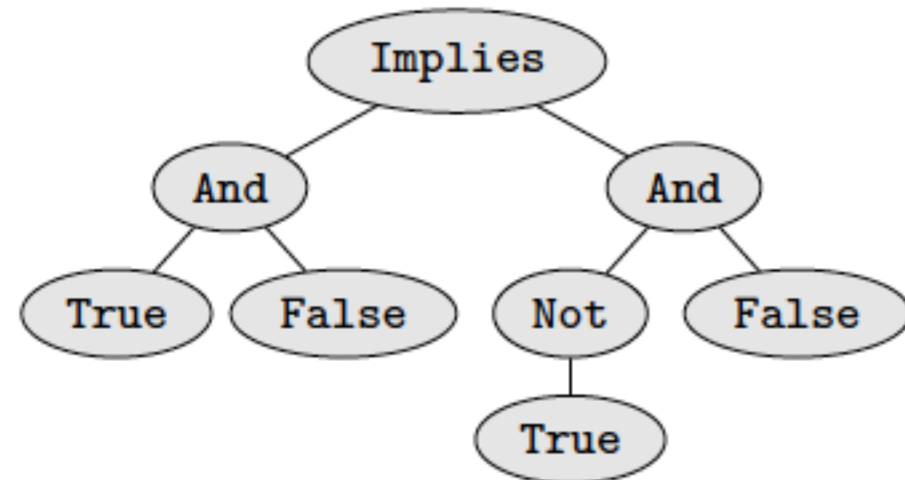

ALBERO SINTATTICO

Semantica dei linguaggi

- Tre metodi principali di analisi semantica
  - ***Semantica operazionale***: descrive il significato di un programma in termini dell'evoluzione (cambiamenti di stato) di una macchina astratta
  - ***Semantica denotazionale***: il significato di un programma è una funzione matematica definita su opportuni domini
  - ***Sematica assiomatica***: descrive il significato di un programma in base alle proprietà che sono soddisfatte prima e dopo la sua esecuzione
- Ogni metodo ha vantaggi e svantaggi rispetto ad aspetti matematici, facilità di uso nelle dimostrazioni, o utilità nel definire un interprete o un compilatore per il linguaggio

E di questo cosa si vede in PR2?

- Metodologie per OOP
  - qualcosa di semantica assiomatica, informalmente
  - clausole Requires & Effect
  - Representation Invariant
- Comprensione dei paradigmi dei linguaggi di programmazione
  - useremo una semantica operazionale

Semantica operazionale

IN SUPREMÆ DIGNITATIS 1343

- **Idea:** la semantica operazionale di un linguaggio **L** definisce ***in modo formale, con strumenti matematici,*** una macchina astratta $\mathbf{M_L}$ in grado di eseguire i programmi scritti in **L**
- Definizione: un ***sistema di transizioni*** è costituito da
  - un insieme **Config** di configurazioni (stati)
  - una relazione di transizione $\dashrightarrow \subseteq$ **Config × Config**
- Notazione: **c** $\dashrightarrow$ **d** significa che **c** e **d** sono nella relazione $\dashrightarrow$
- Intuizione: **c** $\dashrightarrow$ **d** lo stato **c** evolve nello stato **d**

Semantica operazionale “small step”

- Nella semantica operazionale “small step” la relazione di transizione descrive un passo del processo di calcolo
- Abbiamo una transizione **e** –> **d** se partendo dall’espressione (o programma) **e** l’esecuzione di un passo di calcolo ci porta nell’espressione **d**
- Una valutazione completa di **e** avrà quindi la forma
  $\mathbf{e} \rightarrow \mathbf{e_1} \rightarrow \mathbf{e_2} \ldots \rightarrow \mathbf{e_n}$
  dove $\mathbf{e_n}$ può rappresentare il valore finale di **e**
- Nella semantica *small-step* la valutazione di un programma procede attraverso le configurazioni intermedie che può assumere il programma

Semantica operazionale "big step"

- Nella semantica operazionale "big step" la relazione di transizione descrive la valutazione completa di un programma/espressione
- Scriviamo **e** => **v** se l'esecuzione del programma / espressione **e** produce il valore **v**
- Notazione alternativa (equivalente) utilizzata in molti testi: **e** $\Downarrow$ **v**
- Come vedremo, una valutazione completa di un'espressione è ottenuta componendo le valutazioni complete delle sue sotto-espressioni

Semantica operazionale in PR2

- La visione del corso: utilizzeremo la semantica operazionale “big step” come modello per descrivere i meccanismi di calcolo dei linguaggi di programmazione
- La semantica operazionale “small step” sarebbe utile nel caso di linguaggi concorrenti per descrivere le comunicazioni e proprietà quali la deadlock freedom

Semantica operazionale "big step" di espressioni logiche

$$true \Rightarrow true$$

$$false \Rightarrow false$$

VALORI

$$\frac{e \Rightarrow v}{not\ \mathrm{e} \Rightarrow \neg v}(not)$$

$$\frac{e1 \Rightarrow v1 \quad e2 \Rightarrow v2}{e1\ \text{and}\ e2 \Rightarrow v1 \wedge v2}(and)$$

Regole di valutazione analoghe per OR e IMPLIES
Usiamo OPERATORI LOGICI sul
dominio dei valori con tabelle di verità

Regole e derivazioni

- Le regole di valutazione possono essere composte per ottenere la valutazione di una espressione più complessa
- Questo fornisce una prova di una derivazione operazionale di calcolo

$$\dfrac{\dfrac{}{\texttt{True} \Rightarrow \texttt{True}} \qquad \dfrac{\dfrac{}{\texttt{False} \Rightarrow \texttt{False}} \quad \dfrac{}{\texttt{True} \Rightarrow \texttt{True}}}{\texttt{False And True} \Rightarrow \texttt{False}}}{\texttt{True And (False And True)} \Rightarrow \texttt{False}}$$

Regole di derivazione

- Le regole di valutazione costituiscono un *proof system* (sistema di dimostrazione)

$$\frac{premessa_1 \quad \dots \quad premessa_k}{conclusione}$$

- Tipicamente le regole sono definite per induzione strutturale sulla sintassi del linguaggio
- Le "formule" che ci interessa dimostrare sono transizioni del tipo **e => v**
- Componiamo le regole in base alla struttura sintattica di **e** ottenendo un *proof tree*

Regole e interprete

- Le regole di valutazione definiscono l'interprete della macchina astratta "formale" definita dalla semantica operazionale
- Quindi le regole descrivono il processo di calcolo
- Nel corso forniremo una codifica OCaml della semantica operazionale
- Di conseguenza otterremo un modello eseguibile dell'interprete del linguaggio

Interprete espressioni logiche

Passo 1: sintassi astratta

```
type BoolExp =
  | True
  | False
  | Not of BoolExp
  | And of BoolExp * BoolExp
```

Definizione della sintassi astratta tramite i tipi algebrici di OCaml

Passo 2: dalle regole di valutazione all'interprete OCaml

- Obiettivo: definire una funzione **eval** tale che **eval(e) = v** se e solo se **e => v**
- Esempio: dalla regola

$$\frac{e \Rightarrow v}{not \ \mathrm{e} \Rightarrow \neg v}$$

- otteniamo il seguente codice OCaml

```
eval Not(exp0) -> match eval exp0 with
                    True -> False
                  | False -> True
```

Passo 3: Interprete di espressioni logiche (True, False, And, Not)

```
let rec eval exp =
     match exp with
       True -> True
     | False -> False
     | Not(exp0) -> match eval exp0 with
                      True -> False
                    | False -> True
     | And(exp0,exp1) ->
            match (eval exp0, eval exp1) with
              (True,True) -> True
            | (_,False) -> False
            | (False,_) -> False
```

Espressioni a valori interi

Sintassi OCaml (astratta)

```
type expr =
  | CstI of int                          // costanti intere
  | Var of string                        // variabili
  | Prim of string * expr * expr         // operatori binari
```

Ambiente (1)

- Per definire l'interprete dobbiamo introdurre una ***struttura di implementazione (run-time structure)*** che permetta di recuperare i valori associati agli identificatori
- Un **binding** è un'associazione tra un nome e un valore
  – il nome solitamente è utilizzato per reperire il valore
  – esempio in ML

```
let x = 2 + 1 in
  let y = x + x in
    x * y
```

  – il binding di x è 3, il binding di y è 6, il valore calcolato dal programma è 18

Ambiente (2)

- Un ambiente ***env*** è una collezione di binding
- Esempio **env = {x -> 25, y -> 6}**
- L'ambiente **env** contiene due "binding"
  - l'associazione tra l'identificatore **x** e il valore **25**
  - l'associazione tra l'identificatore **y** e il valore **6**
  - l'identificatore **z** non è legato nell'ambiente
- Astrattamente un ambiente è una funzione di tipo

  Ide → Value + Unbound
- L'uso della costante **Unbound** permette di rendere la funzione totale

Notazione

- Dato un ambiente **env: Ide → Value + Unbound**
- **env(x)** denota il valore **v** associato a **x** nell'ambiente oppure il valore speciale **Unbound**
- **env[v/x]** indica l'ambiente così definito
  - **env[v/x](y) = v** se **y = x**
  - **env[v/x](y)** = **env(y)** se **y != x**
- Esempio: se env = {x -> 25, y -> 7} allora

  env[5/x] = {x -> 5, y -> 7}

Implementazione (naïve)

```
let emptyenv = []
(* the empty environment *)

let rec lookup env x =
    match env with
    | []          -> failwith ("not found")
    | (y, v)::r -> if x = y then v else lookup r x
```

Regole di valutazione: codice interprete

$$\frac{env(x) = v}{env \ \triangleright Var\ \mathrm{x} \Rightarrow v}$$

```
eval (Var x) env -> lookup env x
```

$$\frac{env \triangleright e1 \Rightarrow v1 \quad env \triangleright e2 \Rightarrow v2}{env \triangleright \mathrm{Prim}(+, e1, e2) \Rightarrow v1 + v2}$$

```
eval Prim("+", e1, e2) env ->
                         eval e1 env + eval e2 env
```

Interprete per semplici espressioni intere

(* la valutazione è parametrica rispetto a env *)

```
let rec eval e (env : (string * int) list) : int =
    match e with
    | CstI i              -> i
    | Var x               -> lookup env x
    | Prim("+", e1, e2) -> eval e1 env + eval e2 env
    | Prim("*", e1, e2) -> eval e1 env * eval e2 env
    | Prim("-", e1, e2) -> eval e1 env - eval e2 env
    | Prim _              -> failwith "unknown primitive”
```

Ambiente come TDA

- Quali sono le operazioni significative per operare su ambienti?
- **Create( )**
  //EFFECTS: crea l'ambiente vuoto
- **void Bind(x: Ide, v: Value)**
  //EFFECTS: estende this con il legame tra x e v
- **Value Loookup(x : Ide)** throw UnboundException
  //EFFECTS: restituisce il valore associato a x in this. Solleva l'eccezione se this non contiene legami per x

A cosa serve?

- La nozione di ambiente (in letteratura anche nota con il nome di **Name Space Algebra**) viene utilizzata per modellare diversi aspetti dei linguaggi di programmazione
  - tabella dei simboli
  - record di attivazione
  - record (le struct del C)
  - oggetti
  - …

Aggiungiamo le dichiarazioni

let z = 17 **in** z + z

CORPO

DICHIARAZIONE

Espressioni con dich.: sintassi astratta

```
type expr =
   | CstI of int
   | Var of string
   | Let of string * expr * expr
   | Prim of string * expr * expr
```

Esempio

```
Let("z", CstI 17, Prim("+", Var "z", Var "z"))
```

In sintassi concreta

```
let z = 17 in z + z
```

Regola del Let

$$\frac{env \triangleright erhs \Rightarrow xval \quad env[xval / x] \triangleright ebody \Rightarrow v}{env \triangleright \text{Let x = erhs in ebody} \Rightarrow v}$$

```
eval (Let(x, erhs, ebody)) env ->
      let xval = eval erhs env in
        let env1 = (x, xval) :: env in
          eval ebody env1
```

- Si valuta **ehrs** nell'ambiente corrente ottenendo **xval**
- Si valuta **ebody** nell'ambiente esteso con il legame tra **x** e **xval** ottenendo il valore **v**
- La valutazione del "let" nell'ambiente corrente produce il valore **v**

Interprete per espressioni con dichiarazioni

```
let rec eval e (env : (string * int) list) : int =
    match e with
     | CstI i            -> i
     | Var x             -> lookup env x
     | Let(x, erhs, ebody) ->
          let xval = eval erhs env in
             let env1 = (x, xval) :: env in
                 eval ebody env1
     | Prim("+", e1, e2) -> eval e1 env + eval e2 env
     | Prim("*", e1, e2) -> eval e1 env * eval e2 env
     | Prim("-", e1, e2) -> eval e1 env - eval e2 env
     | Prim _            -> failwith "unknown primitive”
```

Variabili libere

- In logica una variabile in una formula è *libera* se non compare nella portata di un quantificatore associato a tale variabile, altrimenti è *legata*

- Esempio: $\forall x.(P(x) \wedge Q(y))$
  [o $(\forall x. P(x) \wedge Q(y))$ nella sintassi di LPP]
  - x è legata
  - y è libera

Occorrenze libere

- La nozione di variabile libera o legata si applica anche al caso del costrutto **let**
- Infatti il costrutto **let** si comporta come un quantificatore per la variabile che introduce
- Un identificatore **x** si dice "legato" se appare nel **ebody** dell'espressione **let x = ehrs in ebody**, altrimenti si dice libero
- Esempi
  - `let z = x in z + x` (* z legata, x libera *)
  - `let z = 3 in let y = z + 1 in x + y`
    (* z, y legate, x libera *)

Interpretazione di espressioni

- L'interprete introdotto ci permette di valutare espressioni costruite con la sintassi indicata

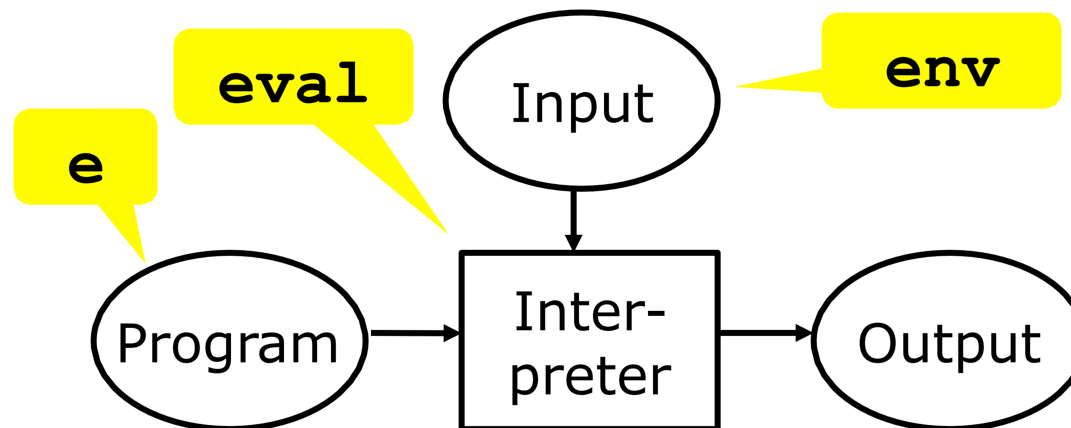

Verso la compilazione

- Il nostro interprete di espressioni ogni volta che deve determinare il valore associato a una variabile effettua una operazione di lookup nell'ambiente: questo potrebbe essere oneroso
- Idea: ottimizzare l'esecuzione introducendo un piccolo compilatore che traduce tutte le occorrenze di identificatori in "indici di accesso", in modo tale che l'operazione di lookup sia eseguita senza effettuare ricerche sull'ambiente, ma in modo diretto (complessità O(1))

Ricordiamo lo schema misto compilazione/interpretazione

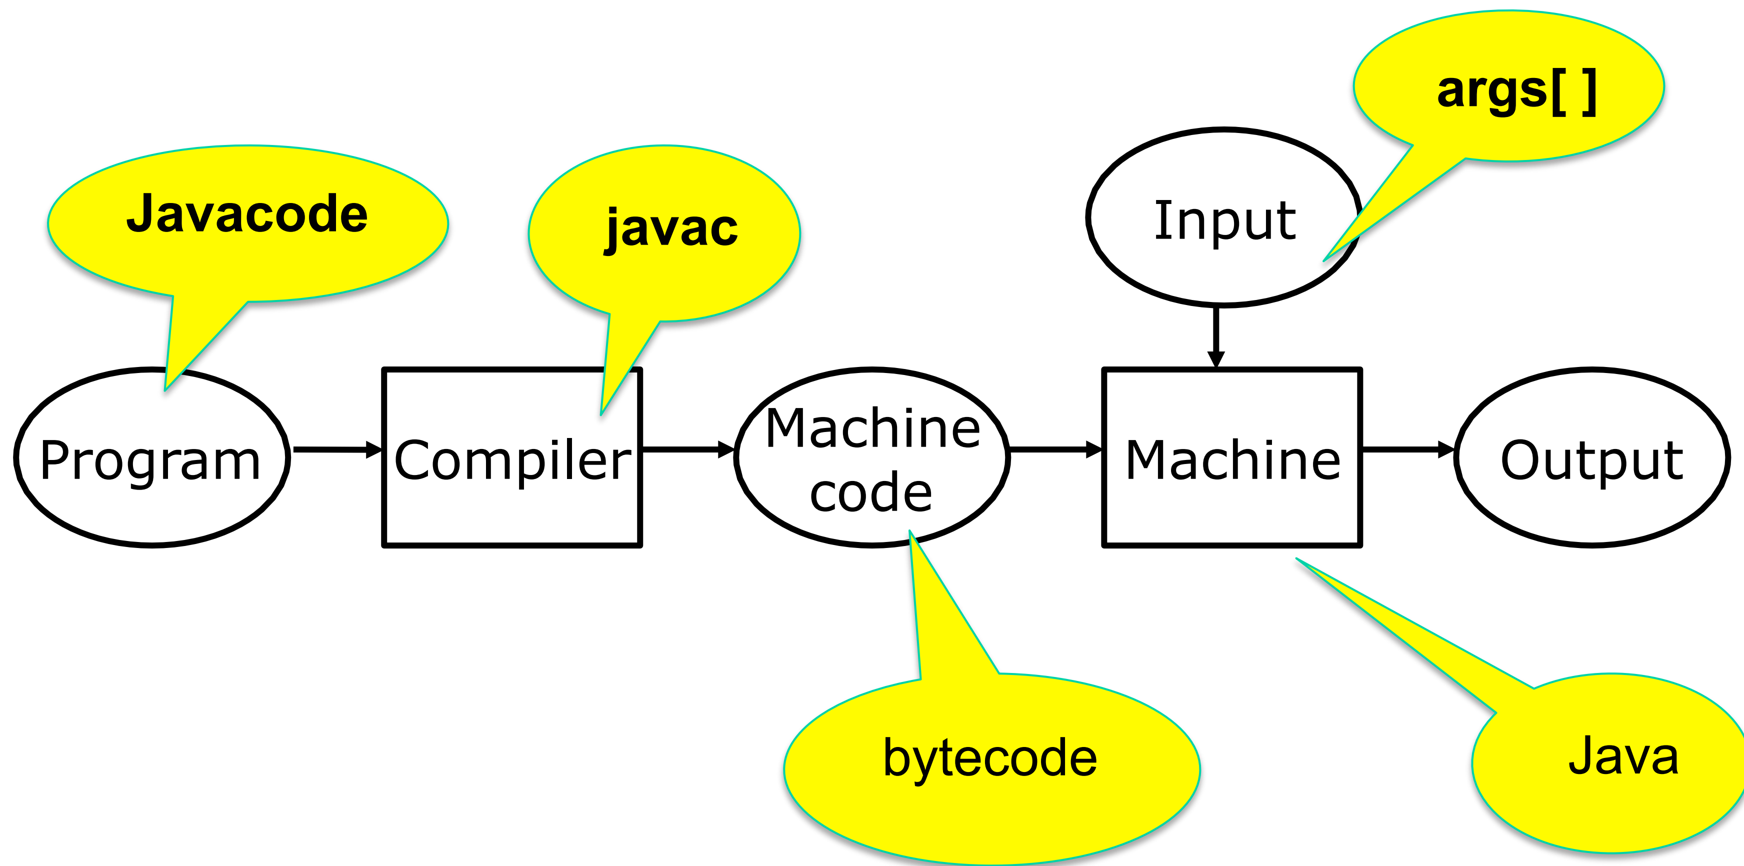

Le variabili: da nomi a indici

```
Let("z", CstI 17, Prim("+", Var "z", Var "z"))
```

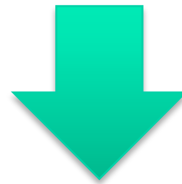

COMPILAZIONE

```
Let(CstI 17, Prim("+", Var 0, Var 0))
```

Il valore 0 indica il binding (let) più vicino

Indici per variabili

Idea: indice di una variabile = numero dei **let** che si attraversano per raggiungerla

```
Let("z", CstI 17,
      Let("y", CstI 25,
             Prim("+", Var "z", Var "y")))
```

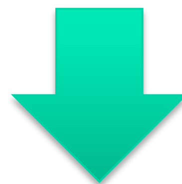

COMPILAZIONE

```
Let(CstI 17,
      Let(CstI 25,
             Prim("+", Var 1, Var 0)))
```

Indici per variabili

- L'idea di utilizzare indici al posto di variabili in modo tale da avere implementazioni efficienti nasce nella teoria del lambda-calcolo con gli indici di De Bruijn

  http://en.wikipedia.org/wiki/De_Bruijn_index

Il linguaggio intermedio

TARGET EXPRESSION

```
type texpr =                          (* target expression *)
   | TCstI of int
   | TVar of int                      (* indice a run time *)
   | TLet of texpr * texpr            (* erhs e ebody *)
   | TPrim of string * texpr * texpr
```

Compilazione in codice intermedio

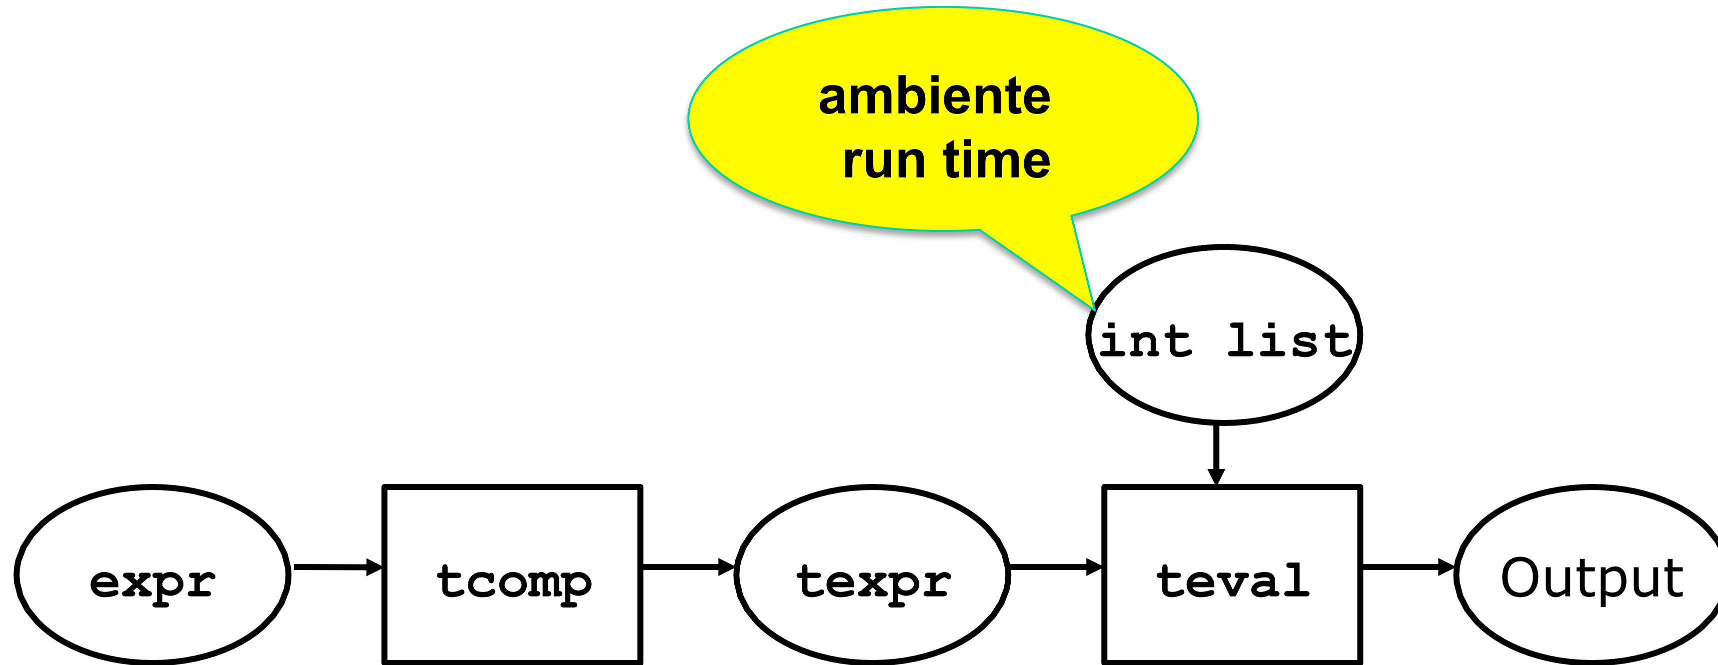

Compilazione in codice intermedio

```
(* Compila Expr in Texpr. Usa lista di identificatori *)

let rec tcomp e (cenv : string list) : texpr =
    match e with
      | CstI i -> TCstI i
      | Var x  -> TVar (getindex cenv x)
      | Let(x, erhs, ebody) ->
              let cenv1 = x :: cenv in
                 TLet(tcomp erhs cenv, tcomp ebody cenv1)
      | Prim(ope, e1, e2) ->
                 TPrim(ope, tcomp e1 cenv, tcomp e2 cenv)

let rec getindex cenv x =
    match cenv with
    | [] -> failwith("Variable not found")
    | y::yr -> if x=y then 0 else 1 + getindex yr x
```

Interpretaz. in codice intermedio

```
(* Ambiente a run time e' una lista di interi *)

open list

let rec teval (e : texpr) (renv : int list) : int =
    match e with
      | TCstI i -> i
      | TVar n  -> nth renv n
      | TLet(erhs, ebody) ->
            let xval = teval erhs renv in
               let renv1 = xval :: renv  in
                  teval ebody renv1
      | TPrim("+", e1, e2) -> teval e1 renv + teval e2 renv
      | TPrim("*", e1, e2) -> teval e1 renv * teval e2 renv
      | TPrim("-", e1, e2) -> teval e1 renv - teval e2 renv
      | TPrim _            -> failwith("unknown primitive")
```

Codice intermedio

- Rappresentare il programma sorgente in un codice intermedio è una tecnica che permette di dominare la complessità della implementazione di un linguaggio di programmazione
- La rappresentazione in codice intermedio permette di effettuare numerose ottimizzazioni sul codice (nel nostro caso, l'eliminazione dei nomi a run-time)
- Esempi
  - Java bytecode: codice intermedio della JVM
  - Microsoft Common Intermediate Language: codice intermedio .NET

Cosa abbiamo imparato

- Una tecnica generale usata nei back-end dei compilatori nella fase di generazione del codice per ottenere un codice maggiormente efficiente
- Usare codice intermedio e ottimizzare il codice oggetto sul codice intermedio
- Articolo divulgativo (ma tecnico) disponibile on-line: Fred Chow, Intermediate Representation, Communications of ACM 56 (12) 2013

Visione Java

FIGURE 1

The Different Levels of Program Representations

levels

high

low

source program	• many language constructs • shortest code sequence • complete program information • hierarchical constructs • unclear execution performance
IR	• fewer kinds of constructs • longer code sequence • smaller amount of program information • mixture of heirarchical and flat constructs • execution performance predictable
machine instructions	• many kinds of machine instructions • longest code sequence • least amount of program information • flat constructs • execution performance apparent

Visione Common Interm. Language