COMPILATORI: MODELLO

- La costruzione di un compilatore per un particolare linguaggio di programmazione è complessa.
  - La complessità dipende dal linguaggio sorgente
- Compilatore: traduce il programma sorgente in programma oggetto.
- Due compiti:
  - ANALISI del programma sorgente
  - SINTESI del programma oggetto

COMPILATORI: MODELLO

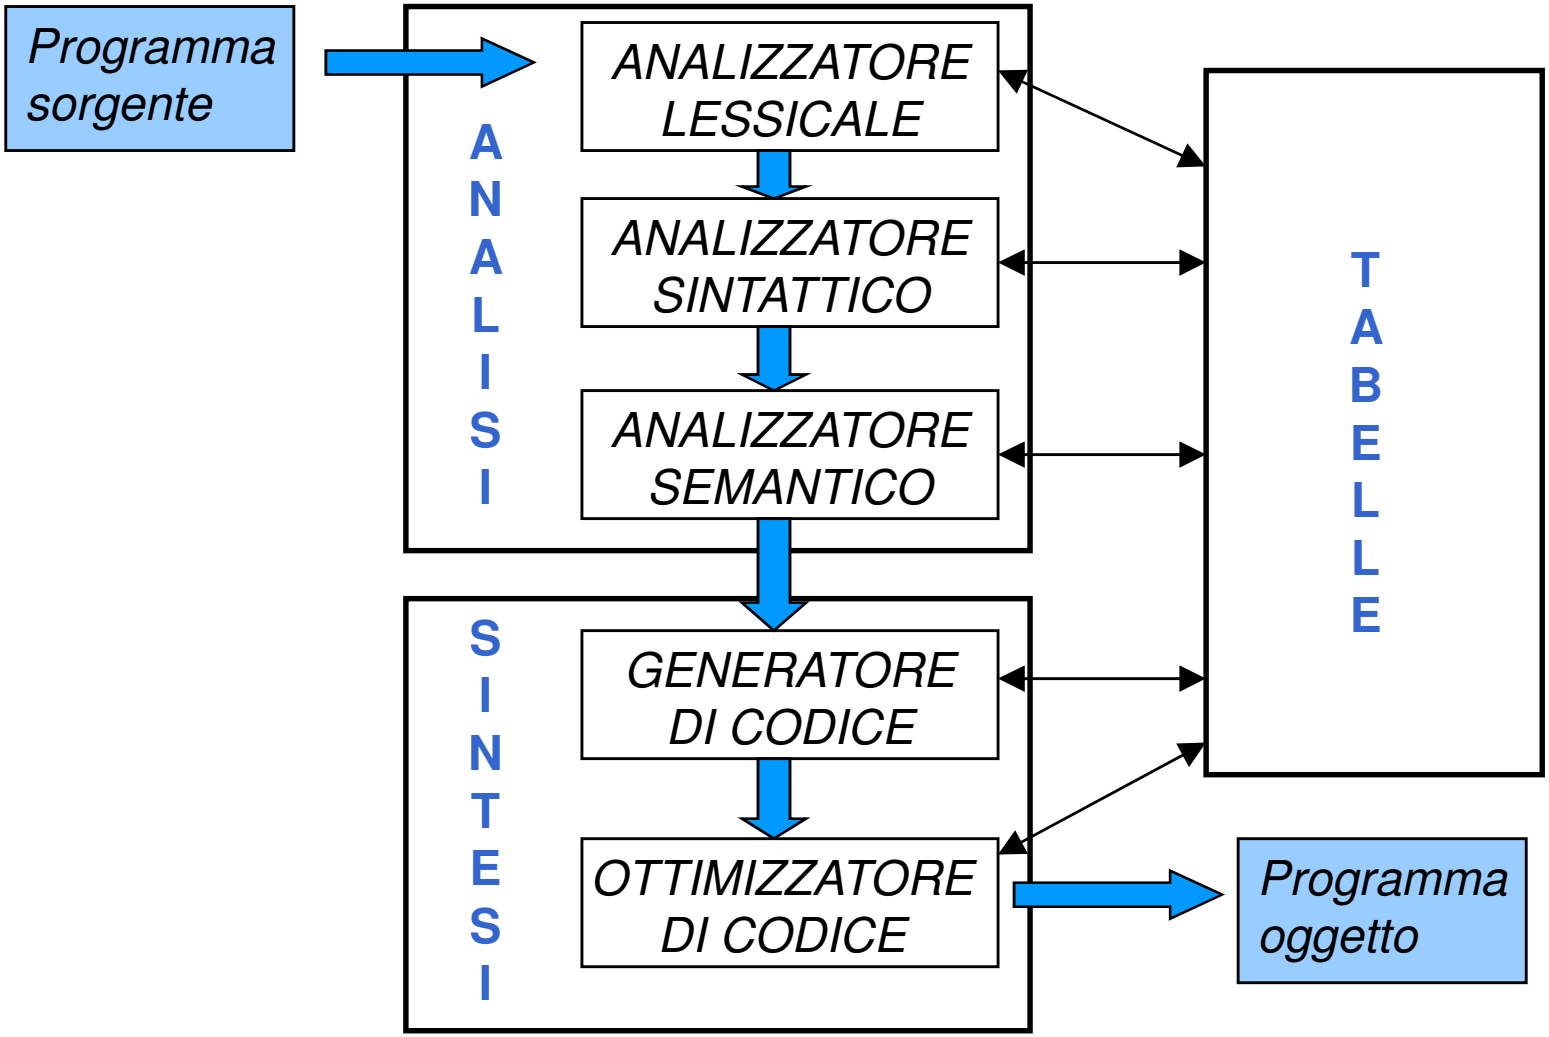

ANALIZZATORE LESSICALE

- Un programma sorgente è una stringa di simboli
- Analizzatore lessicale o *scanner*: esamina il programma sorgente per identificare i simboli che lo compongono (*tokens*) classificando parole chiave, identificatori, operatori, costanti…..
- Ad ogni classe di tokens è associato un numero unico che la identifica.
- Vengono ignorati spazi bianchi e commenti

ANALIZZATORE LESSICALE

- Esempio: **`if A>B then X:=Y;`** è trasformata in

TOKEN	NUMERO
`if`	20
`A`	1
`>`	15
`B`	1
`then`	21
`X`	1
`:=`	10
`Y`	1
`;`	27

Si noti che le variabili sono associate allo stesso numero identificativo

Nella TABELLA dei simboli per ogni variabile ho un elemento contenente:

NOME, TIPO, INDIRIZZO, VALORE, LINEA DICHIARAZIONE

ANALIZZATORE LESSICALE

- Esempio: `X1:= a+bb*12;`
  `X2:= a/2+bb*12;`

TOKEN	CLASSI
X1	id
:=	op
a	id
+	op
bb	id
*	op
12	lit
;	punct

TOKEN	CLASSI
X2	id
:=	op
a	id
/	op
2	lit
+	op
bb	id
*	op
12	lit
;	punct

ANALIZZATORE SINTATTICO

- Il Progetto di uno Scanner e la sua Realizzazione
- Compiti:
  - Eliminare bianchi, commenti ecc;
  - Isolare il prossimo token dalla sequenza di caratteri in input;
  - Isolare identificatori e parole-chiave;
  - Generare la symbol-table.
- I tokens possono essere descritti in modi differenti, ma un modo utilizzato spesso sono le grammatiche regolari.

ANALIZZATORE SINTATTICO

- Analizzatore sintattico o *parser*: individua la struttura sintattica della stringa in esame a partire dal programma sorgente già trasformato sotto forma di tokens: identifica espressioni, istruzioni, procedure…

- Esempio **`ALFA1:= 5 + A*B`**
  - la sottostringa 5 + A * B viene riconosciuta come **`<espressione>`** mentre la stringa completa come **`<assegnamento>`** secondo la regola sintattica Pascal

`<assegnamento>::= <variabile> := <espressione>`

- In realtà viene usata la rappresentazione a classi di token **`id1:= lit1 + id2*id3`**

ANALIZZATORE SINTATTICO

- Il controllo sintattico si basa sulle regole grammaticali utilizzate per definire formalmente il linguaggio

- Durante il controllo sintattico si genera l'albero di derivazione o *albero sintattico*

ALBERI SINTATTICI

```
X1:= a+bb*12;
X2:= a/2+bb*12;
```

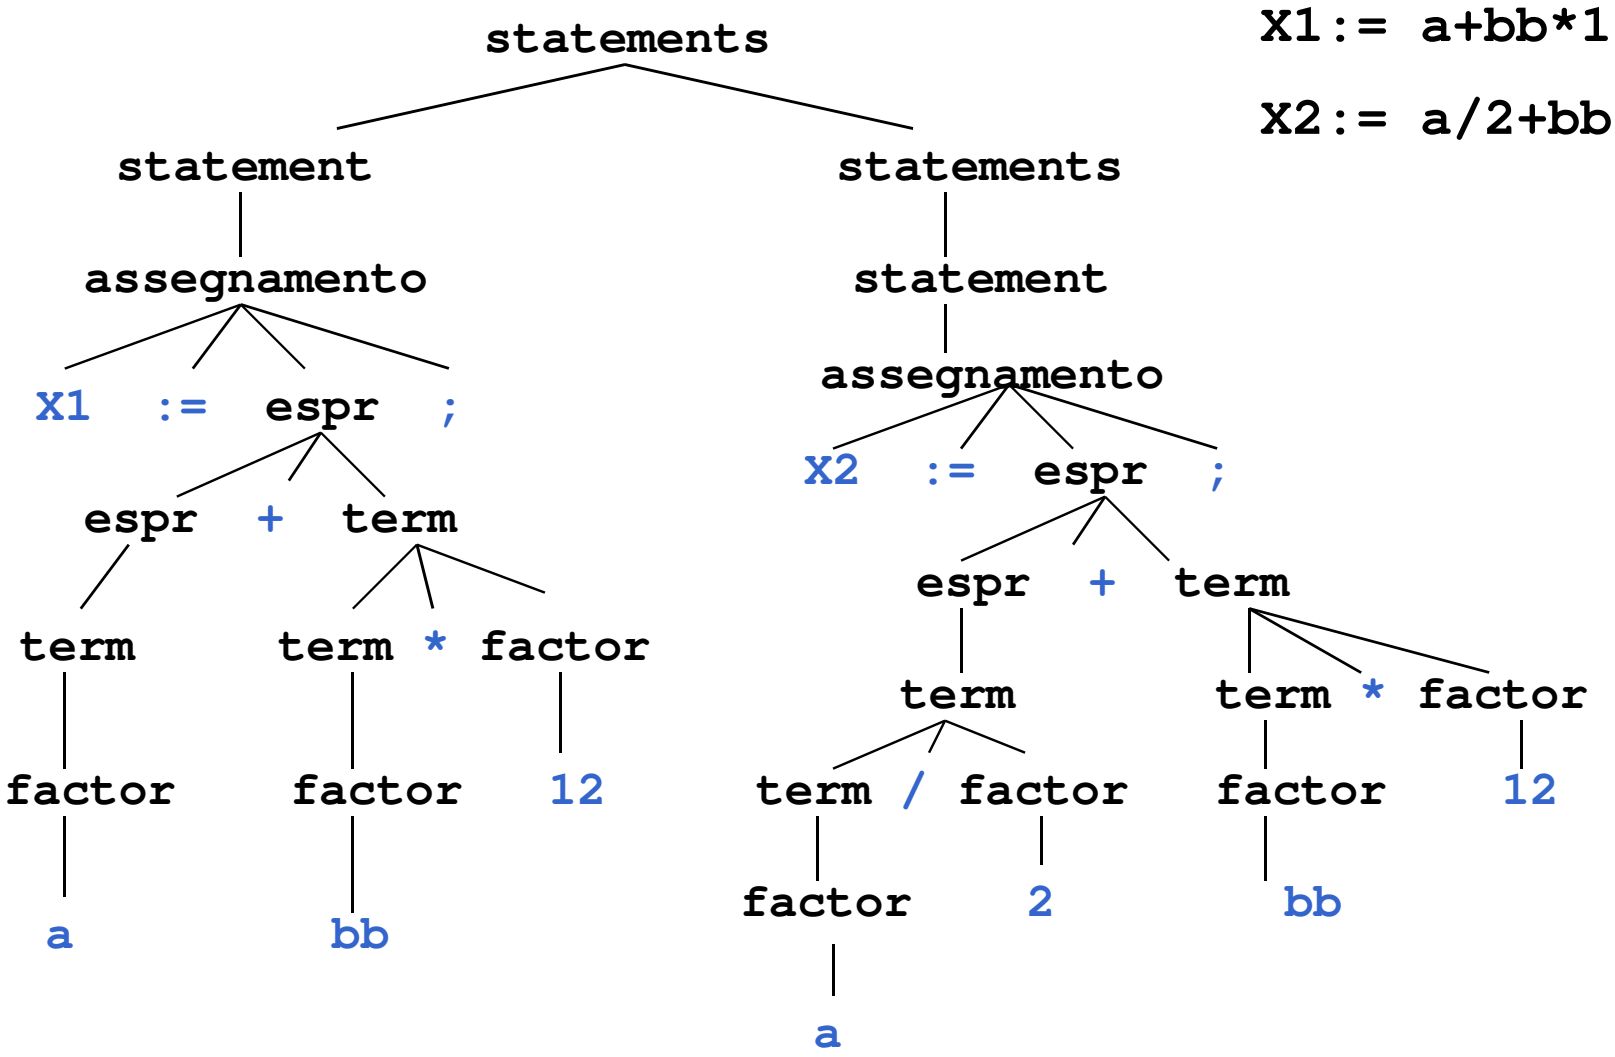

ANALIZZATORE SEMANTICO

- Analizzatore semantico: riceve come ingresso l'albero sintattico generato dal parser.

- Fasi principali
  - CONTROLLO STATICO: vengono svolti i controlli sui tipi, dichiarazioni ecc…
  - AZIONI DA COMPIERE: associazione di routine semantiche associate agli operatori che specificano quali azioni compiere (esempio: tipo operandi conforme all'operatore)
  - GENERAZIONE DI RAPPRESENTAZIONE INTERMEDIA

ANALIZZATORE SEMANTICO

- Considera gli aspetti dipendenti dal contesto

- Esempio (per un linguaggio a bocchi):

```
BEGIN
  INT I;
  ...
END
...
J:=I*K;
```

- Se `I` non e' anche dichiarato nel blocco esterno, `J:=I*K;` e' un'istruzione illegale, anche se sintatticamente corretta.

ANALIZZATORE SEMANTICO

- La soluzione comune per manipolare queste situazioni e' aumentare il lavoro del parser (context-free) con azioni speciali di tipo semantico.

- Esempio: Supponiamo che le dichiarazioni di variabili intere siano considerate con la seguente produzione:

```
<decl statement>::= INT <identifier>;
```

- Il nome simbolico per **<identifier>** e' riconosciuto dallo scanner e inserito nella tabella dei simboli durante l'analisi lessicale.

ANALIZZATORE SEMANTICO

- Quindi, quando il compilatore incontra l'istruzione:

```
J = I * K;
```

  la correttezza dell'utilizzo di `I` e' determinata esaminando la tabella dei simboli.

- Un formalismo ormai accettato per descrivere le azioni semantiche necessarie per il controllo statico nei linguaggi (static checking) sono le **attribute grammars**.
  - Il controllo statico si riferisce al controllo di tipo, il controllo che una variabile sia stata dichiarata, il corretto utilizzo degli indici negli array ecc (dipendono dal particolare linguaggio di programmazione).

ATTRIBUTE GRAMMARS

- Grammatiche context-free in cui sono stati aggiunti attributi e regole di valutazione degli attributi chiamate *funzioni semantiche*.
  - Una attribute grammar specifica sia azioni semantiche sia sintattiche.

- **Attributi:**
  - Sono variabili a cui sono assegnati dei valori.
  - Ogni variabile attributo e' associata con uno o più terminali e non terminali della grammatica.
  - Se si scrive E.*Value* si indica che il non terminale E ha l'attributo *Value* .

ANALIZZATORE SEMANTICO

```
Declaration --> Type Var
Type --> Real | Int
```

- Si possono aggiungere i seguenti attributi:

```
Declaration --> Type Var   Var.Class:=Type.Class
Type --> Real|Int          Type.Class:=LexValue
```

- `LexValue` e' il valore del token (`Real` o `Int`) determinato dall'analizzatore lessicale.

FORMATO INTERMEDIO

Il compilatore, durante la traslazione, può creare una forma sorgente intermedia.

- Nella forma intermedia si ignorano alcuni dettagli tipici della macchina target.

- Alcune forme intermedie
  - Notazione polacca;
  - Notazione a n-tuple;
  - Alberi sintattici astratti;
  - Codice di una macchina astratta.

ANALIZZATORE SEMANTICO

- Esempio `X1:= a+bb*12;`
  `X2:= a/2+bb*12;`

  - controlla che il tipo di X1, a e bb sia corretto rispetto agli operatori e al loro risultato. Inoltre, controlla le dichiarazioni delle variabili.
  - un esempio di rappresentazione intermedia può essere in forma a quadruple

```
(*,B,12,R1)
(+,A,R1,X1)
```

ALBERO SINTATTICO ASTRATTO

- Un esempio di rappresentazione intermedia può essere quella che rimuove dall'albero sintattico alcune categorie intermedie e mantiene solo la struttura essenziale.

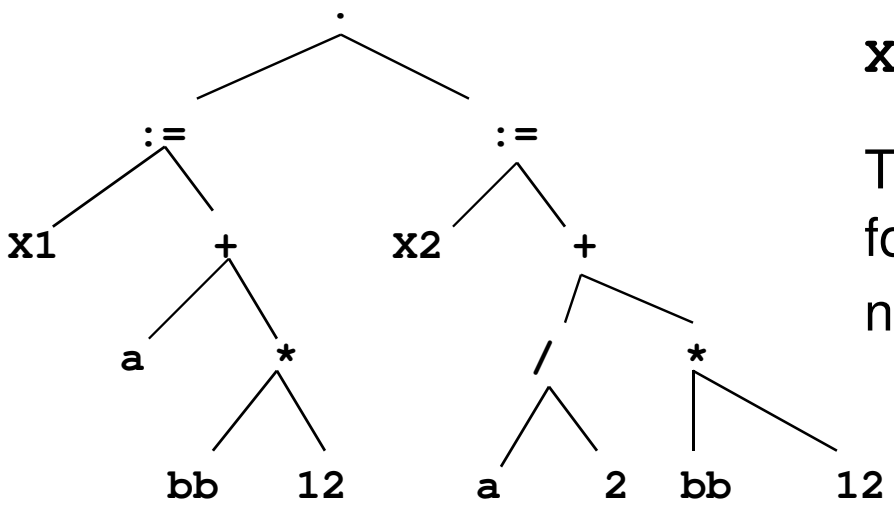


```
X1:= a+bb*12;

X2:= a/2+bb*12;
```

Tutti i nodi sono tokens. Le foglie sono operandi, mentre i nodi intermedi sono operatori

OTTIMIZZAZIONI

- Spesso a valle dell'analizzatorre semantico ci può essere un ottimizzatore del codice intermedio.
  - Propagazione di costanti

```
X:=3;                    X:=3;
A:=B+X;          →       A:=B+3;
```

    evitando un accesso alla memoria

  - Eliminazione di sottoespressioni comuni

```
A:=B*C;                  T:=B*C;
D:=B*C;                  A:=T;
                         B:=T;
```

ALBERO SINTATTICO ASTRATTO

- Eliminando le sottoespressioni comuni, l'albero sintattico diventa un grafo

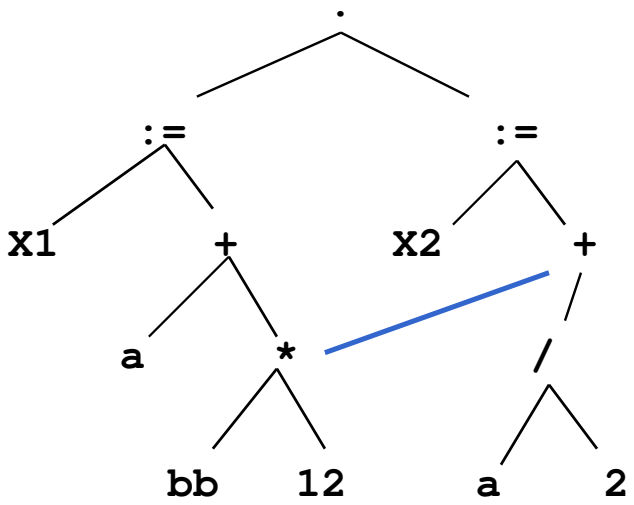


```
X1:= a+bb*12;
X2:= a/2+bb*12;
```

ANALISI: Riassumendo….

- Il compilatore nel corso dell'analisi del programma sorgente verifica la correttezza sintattica e semantica del programma:
  - ANALISI LESSICALE verifica che i simboli utilizzati siano legali cioè appartengano all'alfabeto
  - ANALISI SINTATTICA verifica che le regole grammaticali siano rispettate
  - ANALISI SEMANTICA verifica i vincoli imposti dal contesto

GENERATORE DI CODICE

- Generatore di codice: trasla la forma intermedia in linguaggio assembler o macchina
- Prima della generazione di codice:
  - ALLOCAZIONE DELLA MEMORIA
  - ALLOCAZIONE DEI REGISTRI
- Esempio:

```
X1:= a+bb*12;
X2:= a/2+bb*12;
```

allocare l'espressione bb*12 al registro 1 e una copia del valore di a al registro 3 e il valore a/2 nel registro 2. Le variabili si potrebbero allocare sullo stack con a al top e poi, nell'ordine bb, X1,X2. Il registro S punta al top dello stack. (S) accede al top dello stack, 1(S) ad una posizione successiva, 2(S) a due posizioni successive...

GENERATORE DI CODICE

- Istruzioni pseudo-assembler per una macchina di nostra invenzione

```
                                        X1:= a+bb*12;
PUSHADDR X2
PUSHADDR X1                             X2:= a/2+bb*12;
PUSH bb
PUSH a
LOAD R1 1(S)        mette bb in R1
MPY  12 R1          mette bb*12 in R1
LOAD R2 S           mette a in R2
STORE R2 R3         copia R2 in R3
ADD R1 R3           mette a+b*12 in R3
STORE @2(S)         mette a+b*12 in X1
DIV  2 R2           mette a/2 in R2
ADD R1 R2           mette a/2+b*12 in R2
STORE @3(S)         mette a/2+b*12 in X2
```

GENERATORE DI CODICE IN PROLOG

- Macchina con un singolo registro e con le usuali operazioni aritmetiche più le operazioni di:

  `LOAD Var`

  `STORE Var`

  dove **`Var`** e' la locazione di una variabile.

- Algoritmo
  - Quando riconosce una variabile la inserisce nello stack;
  - Quando riconosce una operazione, gli operandi sono al top dello stack. Se sono variabili genera le seguenti istruzioni:

```
LOAD      1st Operand
Operation 2nd Operand
```

GENERATORE DI CODICE IN PROLOG

- Assumiamo per semplicità che le espressioni siano in notazione Polacca postfissa. Le variabili sono rappresentate da termini **`v(Name)`** e gli operatori da **`op(Op)`**. **`t(X)`** rappresenta una locazione temporanea.

- La procedura principale e':

  `gen_code(Polish, Stack, Temps)`

  – dove **`Polish`** (una lista) e' l'ingresso in forma postfissa, **`Stack`** lo stack e **`Temps`** la lista di indirizzi temporanei.

- Il risultato e' stampato usando **`write`**.

GENERATORE DI CODICE IN PROLOG

```
gen_code([op(Op)|Rest], Stack,Temps):-
  operator(Op,Stack, NewStack,Temps, NewTemps),
  gen_code(Rest, NewStack,NewTemps).

gen_code([v(X)|Rest], Stack,Temps):-
  operand(X,Stack, NewStack,Temps, NewTemps),
  gen_code(Rest, NewStack,NewTemps).

gen_code([],AnyStack,AnyTemps).
```

GENERATORE DI CODICE IN PROLOG

```
% caso (1a):
  Prima di inserire una var nello stack si deve controllare
  se il mark acc occupa la posizione giusta sotto il top
  dello stack. Questa situazione indica la necessita' di
  una locazione di memoria temporanea poiché l'accumulatore
  contiene un valore che non può essere distrutto.
  Allora acc e' rimpiazzato da Ti (locazione di memoria
  temporanea) e si genera l'istruzione:
  STORE Ti. Poi si può inserire la variabile nello stack.
operand(X,[A,acc|Stack],[v(X),A,t(I)|Stack],
                                        Temps,NewTemps):-
  get_temp(t(I),Temps, NewTemps),
  write(store,t(I)).
```

GENERATORE DI CODICE IN PROLOG

```
% caso (1b):
  Se il penultimo elemento dello stack non e' acc,
  semplicemente si inserisce la variabile nello stack.
operand(X,Stack,[v(X)|Stack],Temps,Temps).

% caso (2b):
  Per operazioni commutative (addizione e moltiplicazione)
  basta generare: Operation S1 (se S2 e' in acc)
operator(Op,[A,acc|Stack],[acc|Stack],
                                        Temps,NewTemps):-
  codeop(Op,Instruction,AnyOpType),
  gen_inst(Instruction,A,Temps,NewTemps).
```

GENERATORE DI CODICE IN PROLOG

```
% caso (2c):
   Per operazioni commutative (addizione e moltiplicazione)
  basta generare Operation S2 (se S1 e' in acc).
  operator(Op,[acc,A|Stack],[acc|Stack],
                                        Temps,NewTemps):-
   codeop(Op,Instruction,commute),
   gen_inst(Instruction,A,Temps,NewTemps).
```

GENERATORE DI CODICE IN PROLOG

```
% caso (2d):
  Per le operazioni non commutative (sottrazione e
  divisione) si controlla se S1 e' in acc ed in questo caso
  si genera l'istruzione STORE  Ti, sostituendo acc con Ti;
  poi si procede come in (2). Nel caso invece in cui S2 e'
  in acc si procede come per le operazioni commutative
  (2b).
operator(Op,[acc,A|Stack],[acc|Stack],
                                        Temps,NewTemps):-
  codeop(Op,Instruction,noncommute),
  get_temp(t(I),Temps, Temps0),
  write(store,t(I)),
  gen_instr(load,A,Temps0,Temps1),
  gen_inst(Instruction,t(I),Temps1,NewTemps).
```

GENERATORE DI CODICE IN PROLOG

```
% caso (2a):
(2a) Se ne' S1 ne' S2 e' un acc, il codice e' generato come
  già spiegato al passo 2;


operator(Op,[A,B|Stack],[acc|Stack],
                                        Temps,NewTemps):-
  A=\=acc, B=\= acc,
  codeop(Op,Instruction,OpType),
  gen_instr(load,B,Temps,Temps1),
  gen_inst(Instruction,A,Temps1,NewTemps).
```

GENERATORE DI CODICE IN PROLOG

```
%  procedure ausiliarie
codeop(+,add,commute).
codeop(-,sub,noncommute).
codeop(*,mult,commute).
codeop(/,div,noncommute).

get_temp(t(I),[I,J|R],[J|R]).
get_temp(t(I),[I],[J]):- J is I + 1.

gen_instr(Instruction,t(I),Temps,[I|Temps]):-
  write(Instruction,t(I)).
gen_instr(Instruction,v(A),Temps,Temps):-
  write(Instruction,A).
```

OTTIMIZZATORE DI CODICE

- Il codice generato può essere ottimizzato:
  - ottimizzazioni indipendenti dalla macchina
    - ad esempio rimozione di invarianti di ciclo, rimozione di espressioni duplicate
  - ottimizzazioni dipendenti dalla macchina
    - che riguardano ad esempio l'ottimizzazione sull'uso dei registri

COMPILATORI

- Per ora abbiamo visto tutti i passi effettuati da un compilatore separatamente. In realtà questi passi possono essere uniti.
  - Scanner e parser possono essere eseguiti in sequenza, oppure lo scanner può essere chiamato dal parser ogni volta che necessita di un nuovo token.
  - Parser e analizzatore semantico possono essere uniti.

- Altri aspetti:
  - error detection e recovery
  - tabelle dei simboli generate dai vari moduli
  - gestione della memoria

CONCLUDENDO...

- Spunto per un'esercitazione: come si realizza un generatore di codice a partire da alberi sintattici ?
- Realizzare le varie parti di un compilatore in Prolog.
- Per maggiori dettagli
  - *J Cohen, T.J. Hickey: "Parsing and Compiling Using Prolog" ACM TOPLAS, Vol. 9, N. 2, Aprile 1987;*
  - *D.H.D. Warren: "Logic Programming and Compiler Writing", Software Practice and Experience, Vol 10, 97-125 (1980).*
  - *L.Sterling, E.Shapiro: "The Art of Prolog", The Mit Press, 1987*