POLITECNICO DI TORINO

Laboratorio di Compilatori

Corso di Linguaggi e Traduttori

Esercitazione 2

Stefano Scanzio
mail: stefano.scanzio@polito.it
sito: http://www.skenz.it/traduttori

a.a 2010 / 2011

Riconoscitori e analizzatori sintattici

- Data una grammatica non ambigua ed una sequenza di simboli in ingresso, un riconoscitore è un programma che verifica se la sequenza appartiene o no al linguaggio definito dalla grammatica.
- Un analizzatore sintattico (*parser*) è un programma che è in grado di associare alla sequenza di simboli in ingresso il relativo albero di derivazione.
- Gli algoritmi di analisi possono essere
  - top-down (dalla radice alle foglie)
  - bottom-up (dalle foglie alla radice) : CUP

Scanning e parsing

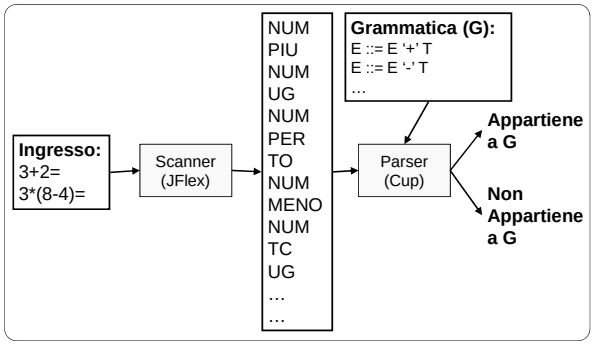

Definizione di grammatica Context-Free

- Una grammatica CF è descritta da:
  - T, NT, S, PR
  - T: Simboli terminali / Tokens passati dallo scanner
  - NT: Simboli non terminali
    - Denotano un set di stringhe generate dalla grammatica
  - S: Simbolo distintivo della grammatica
    - $S \in NT$
    - Definisce tutte le stringhe possibili della grammatica
  - PR: Regola di produzione
    - Indica come i simboli T e NT sono combinati al fine di generare delle stringhe
    - NT ::= T | NT

Esempio

Produzioni (regole grammaticali):

```
assign_stmt ::= ID UG expr PV;
expr ::= expr operatore term;
expr ::= term;
term ::= ID;
term ::= REAL;
term ::= INT;
operator ::= PIU;
operator ::= MENO;
```

- Derivazione:
  - Una sequenza di regole grammaticali che, applicate, trasformano un simbolo non terminale (NT) in una sequenza di simboli terminali (T) che prendono il nome di tokens

Funzionamento di un parser: la tecnica Shift/Reduce

- Si usa uno stack, inizialmente vuoto, per memorizzare i simboli richiesti dal parser allo scanner.
- I simboli terminali vengono immessi sullo stack (azione di shift), fino a che la cima dello stack non contiene un handle (parte destra della regola). Quando ciò avviene, l'handle viene ridotto (azione di reduce) e sostituto con il simbolo non-terminale relativo.
- Si ha successo se esaminati tutti i simboli in ingresso, lo stack contiene solo il simbolo distintivo della grammatica.

Alberi di derivazione e tecnica Shift/Reduce

Stringa di ingresso:
a1 , a2 , a3

Scanner:
a1 , a2 , a3 ::= EL VIR EL VIR EL

Grammatica Ricorsiva Sinistra

```
List ::= List VIR EL
List ::= EL
```

Albero di derivazione

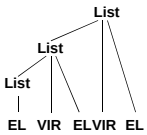

Azione:	Stack:
	ε
Shift:	EL
Reduce:	List
Shift:	List VIR
Shift:	List VIR EL
Reduce:	List
Shift:	List VIR
Shift:	List VIR EL
Reduce:	List

Introduzione a Cup

- Cup è un generatore di analizzatori sintattici che trasforma la descrizione di una grammatica context-free in un programma Java che riconosce ed analizza la grammatica stessa.
- Oltre alle regole sintattiche, è possibile specificare quali azioni devono essere eseguite in corrispondenza del riconoscimento dei vari simboli della grammatica.
- È necessario integrare il parser così generato con un analizzatore lessicale: alcune convenzioni permettono di eseguire l'integrazione di Cup con lo scanner JFlex in modo semplificato.
- Manuale Ufficiale:
  http://www.skenz.it/traduttori/risorse/manualeCup.html

Il formato del file di ingresso

- Il file di ingresso di Cup ha una sintassi molto simile a quella di un programma Java
- Può essere idealmente diviso nelle seguenti sezioni:
  - Setup
  - Terminali e Non Terminali
  - Precedenze (Prossima esercitazione)
  - Regole
- Possono essere introdotti commenti racchiusi dai simboli `/*` e `*/` o preceduti dal simbolo `//`

Sezione di Setup

- Vengono specificate tutte le direttive utili ad un corretto funzionamento del parser
- Inclusione della libreria di Cup e di altre librerie:
  import java_cup.runtime.*;
- Codice utente: (Prossima esercitazione)
  - Ridefinizione di funzioni interne a Cup
  - Integrazione con scanner diversi da JFlex

Sezione dei Terminali / Non-Terminali

- Vengono definiti
  - Simbolo distintivo della grammatica
  - Simboli terminali: passati da Jflex
  - Simboli Non-Terminali
- Simbolo distintivo della grammatica:
  - start with <nome_non_terminale>;
  - Rappresenta la radice dell'albero di derivazione
  - E' lecita una sola occorrenza di questa parola chiave

Sezione dei Terminali / Non-Terminali

- Simboli Terminali
  - terminal <simbolo_terminale_1>,…,<simbolo_terminale_n>;
  - <simbolo_terminale> : Un nome formato da lettere, '_', '.' e cifre (non iniziali).
  - I simboli terminali vengono passati da Jflex o da un altro scanner quando richiesti dal parser
- Simboli Non-Terminali
  - non terminal <simbolo_non_terminale_1>,…,<simbolo_non_terminale_n>;
  - <simbolo_non_terminale> : Un nome formato da lettere, '_', '.' e cifre (non iniziali).

Sezione dei Terminali / Non-Terminali

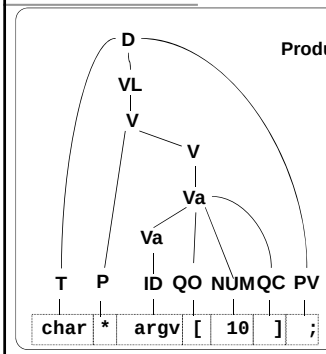

Produzioni (regole grammaticali):

D ::= T Vl PV
VL ::= V
VL ::= VL VIR V
V ::= P V
V ::= Va
Va ::= Va QO NUM QC
Va ::= ID

Stringa di ingresso:
char * argv[10];

Sezione dei Terminali / Non-Terminali

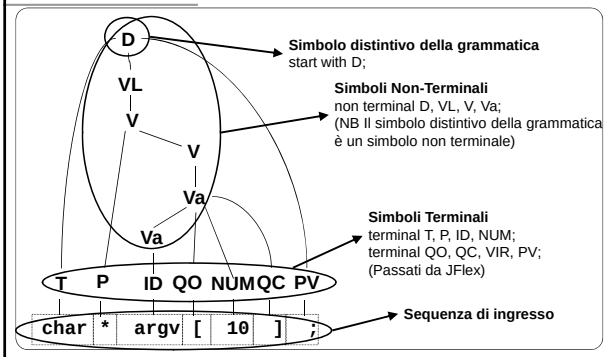

Sezione della Regole

- La sezione delle regole è costituita da una o più regole del tipo:
  <simbolo_non_terminale> **::= CorpoDellaRegola ;**
- dove *CorpoDellaRegola* è una sequenza di 0 o più simboli.
- Ad ogni regola grammaticale può essere associata un'azione racchiusa tra i simboli {: e :}
  - NB. L'azione viene effettuata subito prima dell'operazione di reduce
- Es:

```
D ::= T VL PV
        {: System.out.println("Riconosciuta una dichiarazione di tipo"); :}
    ;
```


Sezione della Regole (2)

- Se per un dato non terminale esistono più produzioni, queste possono essere raggruppate tra loro e separate dal carattere '|'
- Es:

```
funz ::=    tipo ID TO VL TC PV
                {: System.out.println("Riconosciuto prototipo funzione"); :}
          | tipo ID TO VL TC GO stmt_list GC
                {: System.out.println("Riconosciuta funzione"); :}
    ;
```

- NB: A tutti gli effetti queste due regole è come se fossero due regole separate, quindi se volessi eseguire la stessa azione per entrambe le regole, dovrei scrivere due azioni uguali, una per regola

Sezione della Regole: Esempio

```
//Sezione dei Terminali / Non-Terminali
terminal T, P, ID, NUM, PV, VIR, QO, QC;
non terminal D, V, VL, Va;
start with D;

//Sezione delle regole
D ::= T VL PV;

VL::= V
     |VL VIR V;

V ::= P V
     |Va;

Va::= Va QO NUM QC
     |Va;
```

Produzioni (regole grammaticali):

D → T VL PV
VL → V
VL → VL VIR V
V → P V
V → Va
Va → Va QO NUM QC
Va → ID

Integrazione di JFlex e Cup

- Parser e scanner devono accordarsi sui valori associati ai token (simboli terminali della grammatica)
- Lo scanner, ogni volta riconosciuto un simbolo terminale lo deve passare al parser
  - Tale simbolo è una classe di tipo Symbol i cui costruttori fondamentali sono i seguenti:
  - public Symbol(int sym_id)
  - public Symbol(int sym_id, int left, int right)
  - public Symbol(int sym_id, Object o)
  - public Symbol(int sym_id, int left, int right, Object o)
  - La classe Symbol si trova nel seguente file dell'installazione di cup:
    - java_cup/runtime/Symbol.java
- Quando si dichiara un simbolo terminale per mezzo della parola chiave terminal, Cup associa a tale simbolo un valore intero
  - Contenuti nel file sym.java generato da cup durante la compilazione

Integrazione di JFlex e Cup

- Nel caso in cui nel parser siano dichiarati i seguenti simboli terminali:

```
terminal T, P, ID, NUM, PV, VIR, QO, QC;
```

- Potranno essere passarli da scanner a parser, quanto il parser li richiede, nel seguente modo:

```
…
%%
…
%%
[a-zA-Z_][a-zA-Z0-9_]*  {return new Symbol(sym.ID);}
\[                      {return new Symbol(sym.QO);}
\]                      {return new Symbol(sym.QC);}
…
```


Integrazione di JFlex e Cup

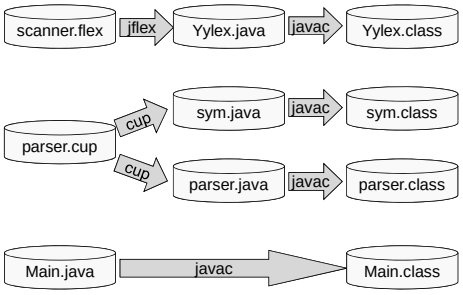

Modifiche allo scanner

scanner.flex

List → List VIRGOLA EL
List → EL

- Includere la libreria di Cup (java_cup.runtime.*) nella sezione del codice
- Attivare la compatibilità con Cup tramite la direttiva %cup nella sezione delle dichiarazioni

```
import java_cup.runtime.*;
…
%%
%cup
…
%%
[a-z]+      {return new Symbol(sym.EL); }
','         {return new Symbol(sym.VIRGOLA); }
```


Il parser Cup

parser.cup

List → List VIRGOLA EL
List → EL

```
import java_cup.runtime.*;

terminal EL, VIRGOLA;
non terminal Lista, List;

start with Lista;

Lista ::= List    {: System.out.println("Lista riconosciuta correttamente"); :}
        |         {: System.out.println("Lista vuota"); :}
;

List ::= List VIRGOLA EL
;

List ::= EL
;
```


Programma principale: Main

Main.java

```
import java.io.*;

public class Main {
    static public void main(String argv[]) {
        try {
            /* Istanzio lo scanner aprendo il file di ingresso argv[0] */
            Yylex l = new Yylex(new FileReader(argv[0]));
            /* Istanzio il parser */
            parser p = new parser(l);
            /* Avvio il parser */
            Object result = p.parse();
        } catch (Exception e) {
            e.printStackTrace();
        }
    }
}
```


Compilazione

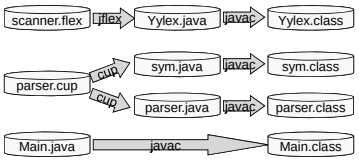

- jflex scanner.jflex
- java java_cup.Main parser.cup
  - Nel caso di conflitti shift/reduce o reduce/reduce:
  - java java_cup.Main -expect <numero_conflitti> parser.cup
  - java java_cup.MainDrawTree parser.cup
    - Può essere usata in laboratorio o installando una versione modificata di cup scaricabile dal sito del corso
    - Lanciando il programma verrà generato anche l'albero di derivazione (funzione utilissima per il debugging della grammatica)

Compilazione

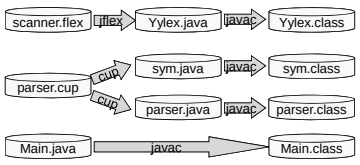

- javac Yylex.java sym.java parser.java Main.java
  - O semplicemente javac *.java
  - Per compilare tutti i file del progetto
- java Main <file>
  - Per eseguire il programma su <file>

http://www.skenz.it/traduttori Esercitazione 2 26