

Compiladores - JACC

Fabio Mascarenhas - 2013.2

<http://www.dcc.ufrj.br/~fabiom/comp>

JACC

- Gerador de analisadores sintáticos LALR que gera código Java
- Sintaxe baseada na sintaxe do YACC (e de muitos outros geradores)
- Rápido, codifica o autômato LALR em código ao invés de usar uma tabela
- Usa o mesmo modelo de *ações semânticas* do YACC, o que permite gerar diretamente uma árvore sintática abstrata a partir da gramática

Usando o JACC

- Linha de comando: `jacc X.jacc`
- `-v`: escreve saída do autômato em arquivo `X.output`
- `-h`: escreve autômato em formato HTML no arquivo `XMachine.html`
- `-fv`, `-fh`: mostra conjuntos **FIRST** e **FOLLOW** para cada não-terminal em conjunto com as opções anteriores
- `-a`, `-s`, `-0`: usa estratégia de parsing **LALR**, **SLR**, ou **LR(0)**

Especificação JACC

- Formato do arquivo de entrada:

```
diretivas
%%
regras
%%
código extra
```

- Diretivas controlam a geração do parser
- Regras especificam a gramática e as ações durante a análise
- Código extra é inserido dentro da classe do parser

Regras

- As regras são onde especificamos as regras da gramática, separando as alternativas de cada não-terminal com `:`, e terminando com `;`;

```
expr : expr '+' term  
     | expr '-' term  
     | term  
     ;
```

```
term : term '*' fact  
     | term '/' fact  
     | fact  
     ;
```

```
fact : '(' expr ')'  
     | NUM  
     ;
```

WPO TEM { }
[]
()

- Terminais (tokens) são caracteres entre `"` ou nomes em maiúsculas

Ações de redução

(1) (2) (3) |

- Cada alternativa pode ter código Java associado que é executado na redução, e pode dizer qual valor deve ser empilhado para aquela redução
- O valor retirado na pilha para cada símbolo da alternativa fica em pseudo-variáveis \$1, \$2, ..., e o valor da pseudo-variável \$\$ é empilhado

```
expr : $1 expr $2 '+' $3 term { $$ = new ast.Soma($1, $3); }
      | expr '-' term { $$ = new ast.Sub($1, $3); }
      | term // default { $$ = $1; }
      ;

term : term '*' fact { $$ = new ast.Mul($1, $3); }
      | term '/' fact { $$ = new ast.Div($1, $3); }
      | fact
      ;

fact : '(' expr ')' { $$ = $2; }
      | NUM { $$ = new ast.Num($1.val); }
      ;
```

Precedência e associatividade

- A gramática pode ser ambígua na parte dos operadores, usando as diretivas %left e %right para resolver a ambiguidade dando a precedência e associatividade dos mesmos
- Precedência é declarada da menor para a maior

```
%left '+' '-'  
%left '*' '/'  
%right '^'
```

```
%%
```

```
expr : expr '+' expr { $$ = new ast.Soma($1, $3); }  
    | expr '-' expr  { $$ = new ast.Sub($1, $3); }  
    | expr '*' expr  { $$ = new ast.Mul($1, $3); }  
    | expr '/' expr  { $$ = new ast.Div($1, $3); }  
    | expr '^' expr  { $$ = new ast.Exp($1, $3); }  
    | NUM             { $$ = new ast.Num($1.val); }  
    ;
```

Operadores unários e binários

- Se um operador tem duas precedências, uma quando é unário e outra quando binário, deve-se usar um pseudo-token e a diretiva %prec na regra:

```
%left '+' '-'
```

```
%left '*' '/'
```

```
%right '^'
```

```
%left NEG
```

pseudo-token

```
%%
```

```
expr : expr '+' expr { $$ = new ast.Soma($1, $3); }  
      | expr '-' expr { $$ = new ast.Sub($1, $3); }  
      | expr '*' expr { $$ = new ast.Mul($1, $3); }  
      | expr '/' expr { $$ = new ast.Div($1, $3); }  
      | expr '^' expr { $$ = new ast.Exp($1, $3); }  
      | '-' expr %prec NEG { $$ = new ast.Neg($2); }  
      | NUM  
      ;
```


Diretivas

- Vários aspectos da configuração do analisador gerado
- %package e %class dão o pacote e o nome da classe do analisador
- %implements diz quais interfaces o analisador deve implementar
- %interface dá o nome da interface gerada com as definições de tokens
- %next dá o nome do método chamado para obter o próximo token, e %get o nome do campo que contém o código do token de lookahead
- %semantic dá o tipo e nome do campo que contém o token de lookahead

Mais diretivas

- %{ e %} permitem embutir código Java antes da classe (imports, por exemplo)
- Diretivas %token dão os nomes de todos os tipos de token que não são dados por um único caractere
- Diretivas %type dão os tipos dos valores semânticos de cada não-terminal da gramática

```
%type <Comando> cmd  
%type <Expressao> exp  
%type <Lvalue> lval  
%type <List> exps cmds
```

Código extra

- Deve-se sempre declarar um método `yyerror` para tratamento de erros sintáticos:

```
void yyerror(String msg) {  
    ...  
}
```

- Também é preciso fazer a adaptação entre a interface do analisador léxico e o que o JACC espera, implementando o método dado na diretiva `%next` e os campos das diretivas `%get` e `%semantic`
- Um bug no JACC faz o método `parse()` gerado não retornar o valor semântico do programa como um todo, então também precisa-se usar um campo auxiliar para isso