Compiladores - Análise Léxica

Fabio Mascarenhas - 2013.1

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

Introdução

- Primeiro passo do front-end: reconhecer *tokens*
  - Tokens são as palavras do programa
  - O analisador léxico transforma o programa de uma sequência de caracteres sem nenhuma estrutura para uma sequência de tokens

```
if x == y then
  z = 1;
else
  z = 2;
```

```
if| |x| |==| |y| |then|\n  |z| |=| |1|;|\n|else|\n  |z| |=| |2|;|<EOF>
```

Tipo do token

- Em português:
  - substantivo, verbo, adjetivo...
- Em uma linguagem de programação:
  - identificador, numeral, if, while, (, ;, ...

Tipo do token

- Cada tipo corresponde a um conjunto de *strings*
- Identificador: *strings de letras ou dígitos, começadas por letra*
- Numeral: *strings de dígitos*
- Espaço em branco: *uma string de brancos, quebras de linha, tabs, ou comentários*
- while: *a string* `while`

Análise léxica

- Classificar substrings do programa de acordo com seu tipo
- Fornecer esses tokens (par tipo e substring) ao analisador sintático

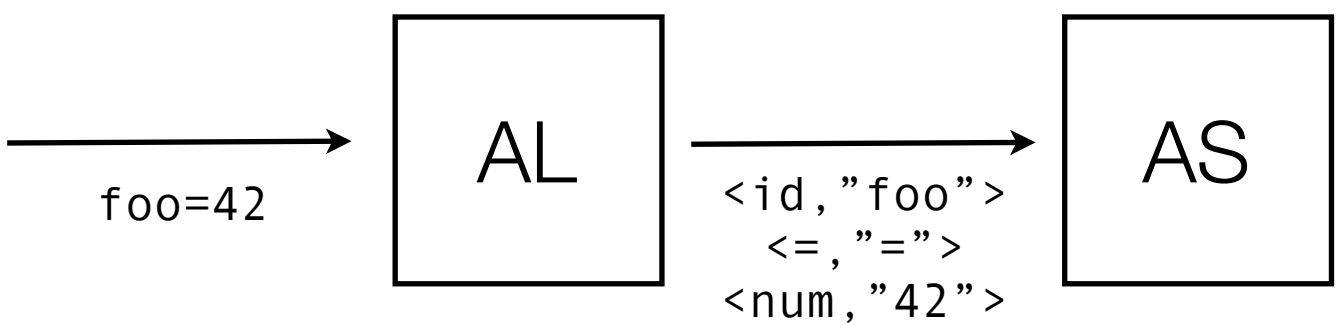

Exemplo

- Para o código abaixo, conte quantos tokens de cada tipo ele tem

```
x = 0;\nwhile (x < 10) {\n\tx++;\n}\n
```

Tipos: id, espaço, num, while, outros

Exemplo

- Para o código abaixo, conte quantos tokens de cada tipo ele tem

```
x = 0;\nwhile (x < 10) {\n\tx++;\n}\n
```

Tipos: id (3), espaço (10), num (2), while (1), outros (9)

Ambiguidade

- A análise léxica de linguagens modernas é bem simples, mas historicamente esse não é o caso

- Em FORTRAN, espaços em branco *dentro de um token* também são ignorados

  - `VAR1` e `VAR  1` são o mesmo token

  - `DO5I=1,25` são 7 tokens: “DO”, “5”, “I”, ‘=’, “1”, “,”, “25”

  - Já `DO5I=1.25` são 3 tokens: “DO5I”, “=”, “1.25”

Ambiguidade

- As palavras-chave de PL/1 não são reservadas
  - `IF ELSE THEN THEN = ELSE; ELSE ELSE = THEN`
- Mas mesmo linguagens modernas têm ambiguidades léxicas
  - ==, ++, +=
  - Templates C++/Generics Java: `List<List<Foo>>` vs `foo >> 2;`
- O analisador léxico precisa manter um “lookahead” para saber onde um token começa e outro termina

Linguagens regulares

- Um tipo de token é um conjunto de strings
- Outro nome para conjunto de strings é *linguagem*
- Geralmente os conjuntos de strings que caracterizam os tipos de tokens de linguagens de programação são *linguagens regulares*
- Em linguagens formais, uma *linguagem regular* é qualquer conjunto de strings que pode ser expresso usando uma *expressão regular*
- Logo, o fato dos tipos de tokens serem linguagens regulares dá uma notação conveniente para especificarmos como classificar os tokens!

Expressões regulares

- Assim como uma expressão aritmética denota um número (por exemplo, “2+3*4” denota o número 14, uma expressão regular denota uma linguagem regular
  - Por exemplo, “a0+” denota a linguagem { “a0”, “a00”, “a000”, ... }
- Vamos explorar expressões regulares usando a função `lex.RE.findAll`, que recebe uma expressão regular e uma string e retorna todas as ocorrências daquela expressão regular na string
  - Ex: `findAll(“a0+”, “a0 fooa000bar a005”) => [“a0”, “a000”, “a00”]`

Caracteres e classes

- *Caracteres* e *classes de caracteres* são o tipo mais simples de expressão regular
- Denotam conjuntos de cadeias de um único caractere
- A expressão “a” denota o conjunto { “a” }, a expressão “x” o conjunto { “x” }
- A expressão “.” é especial e denota o *conjunto alfabeto* (conjunto de todos os caracteres)
- Uma *classe* “[abx]” denota o conjunto { “a”, “b”, “x” }
- Uma classe “[ab-fx]” denota { “a”, “b”, “c”, “d”, “e”, “f”, “x” }
- Uma classe “[^ab-fx]” denota o *conjunto complemento* da classe “[ab-fx]” em relação ao alfabeto

Concatenação ou justaposição

- A concatenação ou justaposição de expressões regulares denota um conjunto com cadeias de vários caracteres, onde cada caractere da cadeia vem de uma das expressões concatenadas

- “[a-z][0-9]” denota o conjunto { “a0”, “a1”, ..., “a9”, “b0”, ..., “b9”, ..., “z9” }

- “while” denota o conjunto { “while” }

- “[wW][hH][iI][lL][eE]” denota o conjunto { “while”, “While”, “wHile”, “WHile”, ... }

- “...” denota o conjunto de todas as cadeias de três caracteres (incluindo espaços!)

Repetição

- O operador + denota a *repetição* de um caractere ou classe de caracteres
  - “[a-z]+” denota o conjunto { “a”, “aa”, “aaa”, ..., “b”, “bb”, ..., “aba”, ... }, ou seja, cadeias formadas de caracteres entre *a* e *z*
  - “[a-z][0-9]+” denota o conjunto { “a0”, “a123”, “d25”, ... }, ou seja, cadeias formadas por um caractere de *a* a *z* seguidas por um ou mais dígitos
- O operador * é uma repetição que permite *zero* caracteres ao invés de ao menos 1
  - “[a-z][0-9]*” denota o conjunto acima, mais o conjunto { “a”, “b”, ... “z” }
  - “\”[^\”]*\”” denota o conjunto de cadeias de quaisquer caracteres entre aspas duplas, exceto as próprias aspas duplas, e inclui a cadeia “\“\””

União e opcional

- Uma barra (|) em uma expressão regular denota a união dos conjuntos das expressões à esquerda e à direita da barra
  - “[a-zA-Z_][a-zA-Z0-9_]*|[0-9]+” é a união do conjunto denotado por “[a-zA-Z_][a-zA-Z0-9_]*” com o conjunto denotado por “[0-9]*”
- O operador ? denota o conjunto denotado pela expressão que ele modifica, mais a cadeia vazia
  - “[0-9]+([.][0-9]+)?” denota o conjunto de todos as sequências de dígitos, mais o conjunto das sequências de dígitos seguidas por um ponto e outra sequência de dígitos

Precedência

- A precedência dos operadores em uma expressão regular, da menor para a maior, é |, depois concatenação, depois +, * e ?
- Naturalmente, podemos usar parênteses para mudar a precedência quando conveniente
- Na prática, é possível escrever uma especificação léxica sem precisar |, ( ) e ?, usando múltiplas regras para a mesma classe de token, e a especificação pode ficar mais legível assim

Especificação léxica

- A especificação léxica de uma linguagem é uma sequência de *regras*, onde cada regra é composta de uma expressão regular e um *tipo de token*

- Uma regra diz que se os próximos caracteres presentes na entrada pertencerem ao conjunto denotado pela sua expressão regular, então o próximo token da entrada pertence ao seu tipo

- Para a linguagem de comandos simples, onde os tokens são numerais inteiros, identificadores, +, -, (,), =, ;, print, uma possível especificação léxica é dada no slide seguinte

Comandos simples

```
[0-9]+     => NUM
[a-zA-Z]+ => ID
[+]        => '+'
[-]        => '-'
[(]        => '('
[)]        => ')'
=          => '='
;          => ';'
print      => PRINT
```

Um fragmento de Java

```
&&                          => E_LOGICO
[|][|]                      => OU_LOGICO
[+]                         => '+'
[+][+]                      => INC
/                           => '/'
[.]                         => '.'
while                       => WHILE
if                          => IF
for                         => FOR
else                        => ELSE
[a-zA-Z]                    => ID
[a-zA-Z_][a-zA-Z0-9_]+      => ID
[0-9]+                      => NUM
[0-9]+[.][0-9]+             => NUM
[0-9]+[.]                   => NUM
[.][0-9]+                   => NUM
["]["]                      => STRING
["][^"\n]+["]               => STRING
```

Ambiguidade na especificação

- Uma especificação mais complexa como a de Java é naturalmente ambígua
  - Uma entrada “123.4” pode ser um token NUM (“123.4”), dois tokens NUM (“123” e “.4”), um token NUM seguido de um ‘.’ seguido de outro NUM (“123”, “.”, “4”), ou variações disso (“1”, “23”, “.4”)
  - Uma entrada “fora” pode ser um token ID (“fora”), ou um token FOR e um ID (“for”, “a”)
  - “while” pode ser tanto um ID quanto um token WHILE
- Precisamos de regras para remoção da ambiguidade

Removendo ambiguidade

- Caso mais de uma regra consiga classificar os próximos caracteres da entrada, dá-se preferência aquela que consegue classificar **o maior número de caracteres**
    - Ou seja, “123.4” é um único token NUM, e “fora” é um token ID
- Se ainda assim existem várias regras que classificam o mesmo número de caracteres, dá-se preferência à que **vem primeiro**
    - Logo, “while” seria classificado como WHILE