Compiladores I

Prof. Ricardo Santos

(cap 3 – Análise Léxica: Introdução, Revisão LFA)

Análise Léxica

- A primeira fase da compilação
- Recebe os caracteres de entrada do programa e os converte em um fluxo de tokens
- Tokens são unidades lógicas que representam um ou mais caracteres
  - Cada palavra-chave é um token. Ex: **then, begin, integer**
  - Cada identificador é um token. Ex: **a, soma, var1**
  - Cada constante é um token. Ex: **123, 123.456, 1.2E3**
  - Cada sinal é um token. Ex: **(, <, <=, +**

Análise Léxica

- A análise léxica é, usualmente, invocada pelo parser cada vez que um novo token é necessário

- A análise léxica é uma fase que processa caracter por caracter. Assim, velocidade é um ponto crítico no projeto de analisadores léxicos

- A análise léxica é dividida em dois processos (executados nesta ordem):
  - Scanning: remove comentários, remove espaços desnecessários
  - Análise léxica: agrupa os caracteres em tokens

Análise Léxica

Token, Padrão e Lexema

- **Token:** é um par consistindo de um nome de token e um valor de atributo opcional. O nome do token é um símbolo abstrato representando um tipo de unidade léxica. Ex: palavra-chave, identificador, número, etc.

- **Padrão:** é uma descrição da forma que os lexemas de um token podem tomar. No caso de uma palavra-chave como um token, o padrão é a seqüência de caracteres que formam a palavra-chave.

- **Lexema:** seqüência de caracteres no programa fonte que associa um padrão a um token e é uma instância do token

Análise Léxica

- Exemplo: **`printf(“Total = %d\n”, score);`**
- **`printf`** e **`score`** são lexemas associando o padrão para o token **`id`**, **`“Total = %d\n”`** é um lexema que associa o padrão **`literal`**
- Outros exemplos:

Token	Lexemas
if	if
else	else
comparison	<=, !=
id	pi, score, D2
number	3.14159, 0, 6.02e23
literal	“core dumped”

Análise Léxica

- Baseando-se na tabela de tokens e lexemas, determine os lexemas do código a seguir:

```
float quadradolimitado(x) float x{
/* retorna o quadrado limitado de x */
  float retorno;
  if ((x<=-10.0) || (x>=10.0))
    retorno=100;
  else
    retorno=x*x;
  return retorno;
}
```

Token	Lexemas
if	if
else	else
comparison	<=, !=
id	pi, score, D2
number	3.14159, 0, 6.02e23
literal	“core dumped”

Análise Léxica

Questões de Implementação

- Implementação típica: uma função que devolve o código do próximo símbolo de entrada e, eventualmente, o seu valor

- Algumas linguagens apresentam dificuldades particulares, como o uso de palavras-chave (mas não reservadas) como identificadores

- Alternativas para implementação:
  - Abordagens ad hoc
  - Ferramentas automáticas: lex, flex, Jlex, Jflex, etc.

Análise Léxica

Abordagem Ad Hoc

- Se o próximo caractere é um símbolo especial; verifique se pode ter mais de um caractere (ex: <=) e devolva o seu código
- Se o próximo símbolo é um dígito (ou, símbolo de sinal), tratar o resto do número e retornar o código (inteiro, real, double, etc.) e o valor
- Se o próximo símbolo pode iniciar um identificador, trate o resto dele; se for uma palavra reservada, devolva o código correspondente; senão, devolva o código de identificador e o valor da cadeia
- Se o próximo símbolo indica o início de uma cadeia, trate o resto dela e devolva o código de cadeia e o seu valor
- Para fins de mensagens de erro e de depuração, mantenha variáveis convenientes com o nome do arquivo, o número da linha, posição na linha, etc.

Análise Léxica

Erros léxicos

- É difícil para o analisador léxico informar que há erros no código fonte sem o auxílio de outros componentes
- Exemplo: `fi ( a == f(x) )`
  - O léxico não consegue determinar se `fi` é um erro de digitação da palavra-chave `if` ou se é um identificador (um nome de função)
- Mas, e se o léxico não consegue determinar qual padrão mapeia para a entrada atual?
- Nesse caso, uma estratégia (*panic-mode*) é apagar os caracteres da seqüência até que o léxico possa determinar um token válido
- Outras ações possíveis são: inserir um caracter válido, substituir um caracter por outro, transpor dois caracteres adjacentes.

Gramáticas e Linguagens - Revisão

- Alfabeto ou vocabulário: conjunto finito e não vazio de símbolos;
  - Σ^1={a,b} (conjunto de duas letras
  - Σ^2={0,1,2,3,4,5,6,7,8,9} (conjunto de dígitos decimais)
  - Σ^3={**if, then, else, while, id, :=, <, >, =**, ...} (conjunto de símbolos de uma linguagem de programação: cada símbolo é considerado um átomo
- Se $\alpha=\sigma^1\sigma^2...\sigma^n$ com $\sigma^i \in \Sigma$, então α é uma cadeia sobre o alfabeto Σ, de comprimento n; Exemplo: 'abaa' é uma cadeia sobre Σ^1, de comprimento 4
- O símbolo ε (no texto λ) denota a cadeia vazia de comprimento zero

Gramáticas e Linguagens - Revisão

- Dada uma cadeia α:
  - $\alpha^0=\varepsilon$
  - $\alpha^n=\alpha^{n-1}\alpha$ para n>0 (concatenação n vezes)
- Dado um alfabeto Σ
  - Σ^* é o conjunto de todas as cadeias finitas sobre Σ
  - Σ^+ é o conjunto de todas as cadeias finitas sobre Σ, exceto a cadeia vazia
- Uma linguagem sobre Σ é um subconjunto de Σ^*
- Dadas duas linguagens L^1 e L^2 sobre um alfabeto Σ, a concatenação (ou o produto) é dado por $L^1L^2=\{\alpha\beta \mid \alpha \in L^1 \text{ e } \beta \in L^2\}$

Gramáticas e Linguagens - Revisão

- Dada uma linguagem L
  - $L^0=\{\varepsilon\}$
  - $L^n=L^{n-1}L$ para $n>0$
  - $L^*=\cup_{n>=0}L^n$
  - $L^+=\cup_{n>=0}L^n$
- Dada uma cadeia a, a notação será estendida para:
  - $a^*=\{a\}^*$
  - $a^+=\{a\}^+$

Gramáticas e Linguagens - Revisão

- Exemplo: gramática de expressões simples
  - E ← a
  - E ← b
  - E ← E + E
  - E ← E * E
  - E ← (E)
  - Ou sob a forma abreviada: E ← a |b |E + E |E * E| (E)
- Vocabulário terminal T: {a,b,+,*,(,)}
- Vocabulário não-terminal N: {E}
- Símbolo inicial S (raíz): E
- Produção P (exemplo): E ← E * E
- Gramática livre de contexto: G=(T, N, P, S)

Gramáticas e Linguagens - Revisão

- Caso particular de linguagens livres de contexto
- Podem sre descritas por gramáticas cujas produções têm uma forma particular; exemplo:

– $S \leftarrow a$		$S \leftarrow a$
– $S \leftarrow b$	ou	$S \leftarrow b$
– $S \leftarrow aS$		$S \leftarrow Sa$
– $S \leftarrow bS$		$S \leftarrow Sb$

- Todas as ocorrências de símbolos não terminais estão no fim (ou no início) dos lados direitos das produções
- As duas gramáticas descrevem a linguagem que contém todas as cadeias finitas e não vazias sobre o alfabeto {a, b}; exemplo, usando a primeira gramática:

$$S \rightarrow aS \rightarrow abS \rightarrow abbS \rightarrow abbaS \rightarrow abbab$$

Gramáticas e Linguagens - Revisão

- Expressões regulares possibilitam descrever, de forma simples, linguagens regulares
- Dado um alfabeto S:
  - para todo $\sigma \in \Sigma$, "σ" é uma expressão regular que denota a linguagem $\{\sigma\}$
  - se "α" e "β" são duas expressões regulares denotando as linguagens $L\alpha$ e $L\beta$, então "$\alpha\beta$" é uma expressão regular que denota a linguagem produto $L\alpha L\beta$
  - Se "α" e "β" são duas expressões regulares denotando as linguagens $L\alpha$ e $L\beta$, então "$\alpha|\beta$" é uma expressão regular que denota a linguagem união $L\alpha \cup L\beta$
  - Se "α" é uma expressão regular que denota a linguagem $L\alpha$ então "α^*" é uma expressão regular que denota a linguagem $L\alpha^*$
  - Se "α" é uma expressão regular que denota a linguagem $L\alpha$ então "(α)" é uma expressão regular que denota a mesma linguagem

Gramáticas e Linguagens - Revisão

- Qual a linguagem descrita pelos exemplos a seguir?
  - Exemplo 1: (a|b)(a|b)*
  - Exemplo 2: a(aa|ab|ba|bb)*b
  - Exemplo 3: (a|b|c|d|...|z|)(a|b|c|d|...|z|0|1|...|9|)*

Gramáticas e Linguagens - Revisão

- É possível demonstrar que expressões regulares descrevem a mesma classe de linguagens aceitas por autômatos finitos
- Exemplo1: o seguinte autômato aceita a linguagem descrita por (a|b)(a|b)*

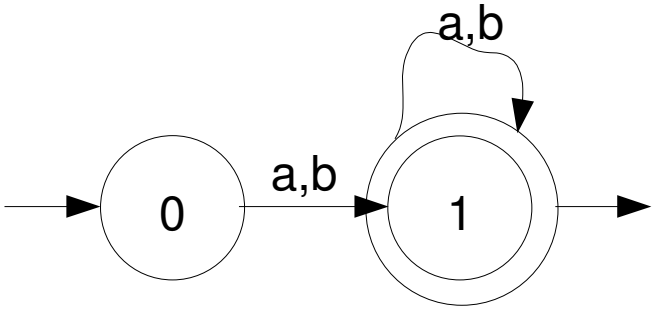

- Por convenção, o estado inicial tem o rótulo 0; o círculo duplo indica estado final (aceitação)

Gramáticas e Linguagens - Revisão

- Exemplo1: o seguinte autômato aceita a linguagem descrita por (a|b)(a|b)*

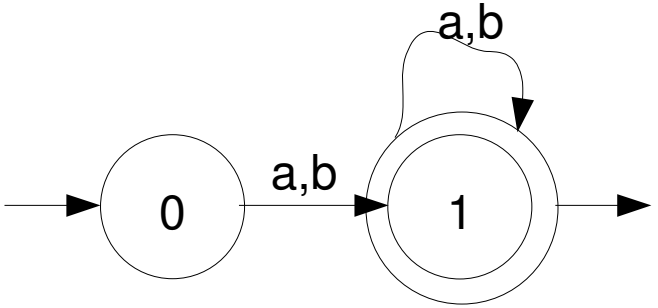


```
L0: if inchar in {a,b} goto L1
    reject()
L1: advance()
    if inchar in {a,b} goto L1
    accept()
```

- Como seria um autômato para reconhecer a seguinte expressão regular: a(aa|ab|ba|bb)*b?