Construção de Compiladores

Capítulo 2

Análise Léxica

José Romildo Malaquias

Departamento de Computação
Universidade Federal de Ouro Preto

2013.1

Layout

1. Análise Léxica

Análise léxica

- **Análise léxica** é o processo onde a sequência de caracteres que constitui o progrma fonte é lida da esquerda para a direita e agrupada em **tokens**.
- **Token** é uma sequência de caracteres com um significado coletivo.
- Usualmente há apenas um pequeno número de tokens para uma linguagem de programação:
  - constantes (inteiros, ponto-flutuante, caracteres, strings, etc.)
  - operadores (aritméticos, relacionais, lógicos)
  - sinais de pontuação
  - palavras reservadas

Analisador léxico

- O **analisador léxico** recebe um programa fonte como entrada e produz uma sequência de tokens como saída.

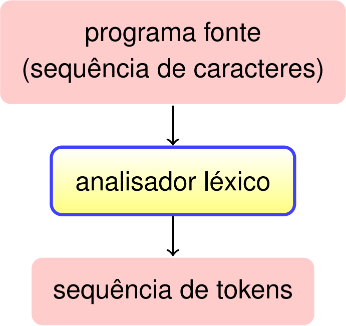

Exemplo de análise léxica

```
while (cont > 0)
  cont = cont - 2;
```

análise léxica →

```
T_While
T_LParen
T_Identifier "cont"
T_Gt
T_Integer 0
T_RParen
T_Identifier "cont"
T_Eq
T_Identifier "cont"
T_Minus
T_Integer 2
T_Semicolon
```

Lexemas

- O analisador léxico pode reconhecer instâncias particulares de tokens, tais como
  - `3` ou `255` para um token constante inteira
  - `"Fred"` ou `"Wilma"` para um token constante string
  - `numTicketes` ou `queue` para um token nome de variável
- Instâncias específicas de um token são chamadas de **lexemas**.
- Um lexema é sequência de caracteres que forma o token.
- Um token é uma classe geral à qual o lexema pertence.
- Alguns tokens tem exatamente um lexema (exemplo: o caracter >)
- Outros tokens tem vários lexemas (como as constantes inteiras).

Tarefas do analisador léxico

O analisador léxico:

- Deve agrupar os caracteres da entrada em tokens válidos.
- Tem uma visão muito localizada do programa fonte, sem qualquer contexto.
- Logo não pode verificar por exemplo se:
  - a sequência dos tokens está correta
  - um token ocorre em uma posição incorreta
  - um identifiador foi declarado
  - uma palavra-chave foi escrita erradamente
- Pode relatar por exemplo:
  - caracter inválidp, a partir do qual não é possível formar nenhum token
  - ocorrências inválidas de caracteres em constantes strings
  - strings não terminadas
  - comentários não terminados

Tarefas do analisador léxico (cont.)

- Pode descartar os caracteres brancos e comentários que aparecem entre os tokens.
- Pode realizar substituição de macros, compilação condicional ou inclusão de arquivos, embora estas tarefas possam ser mais apropriadas a um **preprocessador** que filtra a entrada antes de passá-la ao compilador.

Implementação de expressões regulares

- Expressões regulares podem ser implementadas usando autômatos finitos.
- Há dois tipos de autômato finito:
  - NFAs (autômato finito não-determinístico), e
  - DFAs (autômato finito determinístico).

Autômatos finitos não determinísticos

- Um **autômato finito não determinístico** (NFA) é uma quíntupla

$$(S, \Sigma, \delta, s_0, F)$$

  onde
  - S é um conjunto finito de estados
  - Σ é um alfabeto, um conjunto finito de símbolos de entrada
  - δ é uma função de transição que dá para cada estado $s \in S$ e para cada símbolo a em $\Sigma \cup \{\varepsilon\}$, um conjunto de etados seguintes $\delta(s,a) \in \mathcal{P}(S)$
  - $s_0 \in S$ é o estado inicial
  - $F \subseteq S$ é o conjunto de estados finais, que são distinguidos como estados de aceitação
- O símbolo ε representando a cadeia vazia não é um elemento do alfabeto.

Exemplo de autômato finito

Autômato que reconhece $\mathcal{L}((a|b)\star abb)$:

$$A = (\Sigma, S, \delta, s_0, F)$$

onde

$$\begin{aligned}
\Sigma &= \{a, b\} && \text{alfabeto} \\
S &= \{0, 1, 2, 3\} && \text{conjunto de estados} \\
\delta &= \{(0,a) \mapsto \{0,1\}, && \text{função de transição} \\
&\quad (0,b) \mapsto \{b\}, \\
&\quad (0,\varepsilon) \mapsto \{\}, \\
&\quad (1,a) \mapsto \{\}, \\
&\quad (1,b) \mapsto \{2\}, \\
&\quad (1,\varepsilon) \mapsto \{\}, \\
&\quad (2,a) \mapsto \{\}, \\
&\quad (2,b) \mapsto \{3\}, \\
&\quad (2,\varepsilon) \mapsto \{\} \quad \} \\
s_0 &= 0 && \text{estado inicial} \\
F &= \{3\} && \text{conjunto de estados finais}
\end{aligned}$$

- Um autômato finito pode ser representado por um **grafo de transição** onde
  - os nós representam os estados
  - as arestas rotuladas representam a função de transição
  - o estado inicial é indicado por uma aresta sem origem
  - os estados finais são indicados por nós com bordas duplas

Tabela de transição

- Um autômato finito pode ser representado por uma **tabela de transição** onde
  - as linhas correspondem aos estados
  - as colunas correspondem aos símbolos de entrada e ε
  - a entrada da tabela para um determinado estado e um símbolo da entrada (ou ε) representa o valor da função de transição aplicada a esses argumentos
- **Vantagem**: as transições são facilmente encontradas.
- **Desvantagem**: ocupa muito espaço quando o alfabeto de entrada é grande, mesmo que muitos estados não tenham transições com a maioria dos símbolos da entrada (e ε).

Exemplo de autômato finito

Autômato que reconhece $\mathcal{L}((a|b)\star abb)$:

$$A = (\Sigma, S, \delta, s_0, F)$$

$$\Sigma = \{a, b\}$$

$$S = \{0, 1, 2, 3\}$$

$$\begin{aligned}\delta = \{&(0,a)\mapsto\{0,1\},\\ &(0,b)\mapsto\{b\},\\ &(0,\varepsilon)\mapsto\{\},\\ &(1,a)\mapsto\{\},\\ &(1,b)\mapsto\{2\},\\ &(1,\varepsilon)\mapsto\{\},\\ &(2,a)\mapsto\{\},\\ &(2,b)\mapsto\{3\},\\ &(2,\varepsilon)\mapsto\{\}\quad\}\end{aligned}$$

$$s_0 = 0$$

$$F = \{3\}$$

Tabela de transições:

estado	a	b	ε
0	$\{0,1\}$	$\{0\}$	$\{\}$
1	$\{\}$	$\{2\}$	$\{\}$
2	$\{\}$	$\{3\}$	$\{\}$
3	$\{\}$	$\{\}$	$\{\}$

Grafo de transições:

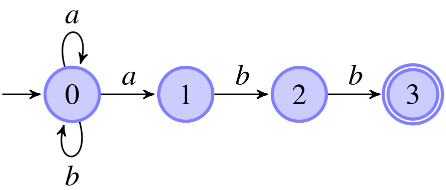

Exemplo de autômato finito

Autômato que reconhece $\mathcal{L}(a * (a|b))$:

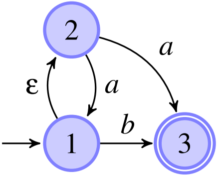

Exemplo de autômato finito

Autômato que reconhece $\mathcal{L}((0|1)*1)$:

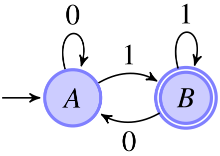

Exemplo de autômato finito

Autômato que reconhece $\mathcal{L}(aa*|bb*)$:

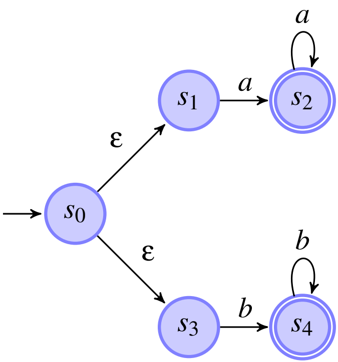

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

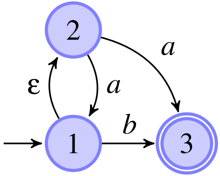

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

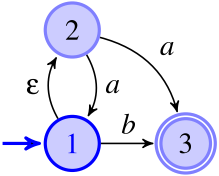

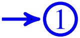

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

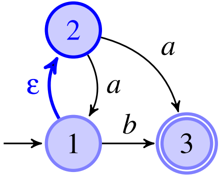

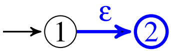

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

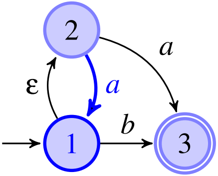

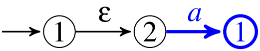

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

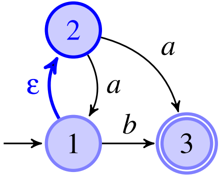

$$\rightarrow 1 \xrightarrow{\varepsilon} 2 \xrightarrow{a} 1 \xrightarrow{\varepsilon} 2$$

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

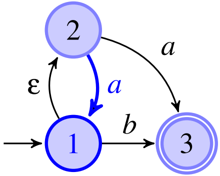

$$\rightarrow 1 \xrightarrow{\varepsilon} 2 \xrightarrow{a} 1 \xrightarrow{\varepsilon} 2 \xrightarrow{a} 1$$

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

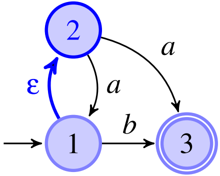

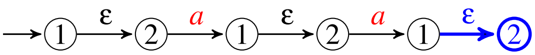

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

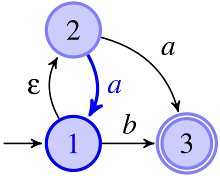

$$\rightarrow (1) \xrightarrow{\varepsilon} (2) \xrightarrow{a} (1) \xrightarrow{\varepsilon} (2) \xrightarrow{a} (1) \xrightarrow{\varepsilon} (2) \xrightarrow{a} (1)$$

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

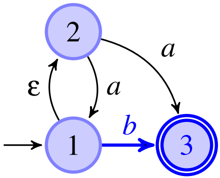

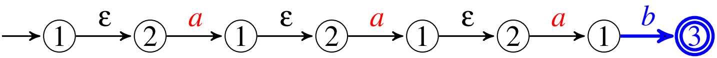

Aceitação de cadeias pelo autômato finito

- Um autômato finito aceita uma cadeia de entrada x se e somente se houver algum caminho no grafo de transição do estado inicial para um dos estados finais, de modo que os símbolos ao longo do caminho componham x.
- Exemplo: o autômato a seguir aceita a cadeia $aaab$:

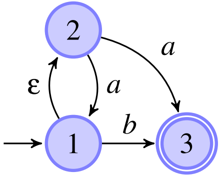

$$\to 1 \xrightarrow{\varepsilon} 2 \xrightarrow{a} 1 \xrightarrow{\varepsilon} 2 \xrightarrow{a} 1 \xrightarrow{\varepsilon} 2 \xrightarrow{a} 1 \xrightarrow{b} (3)$$

Linguagem aceita por um autômato finito

- A **linguagem** $L(A)$ **definida** (ou **aceita**) pelo autômato finito A é o conjunto de todas as cadeias rotulando algum caminho a partir do estado inicial até um estado final de A.

Simulação de um NFA

- Mantenha um conjunto de estados atuais, inicialmente dado pelo estado inicial e todos os estados alcançados por transições vazias.
- Para cada caracter da entrada:
  - Matenha um conjunto dos próximos estados, inicialmente vazio.
  - Para cada estado atual:
    - Siga todas as transições rotuladas com o símbolo atual.
    - Adicione estes estados ao conjunto de novos estados.
  - Adicione todo estado alcançado por transições vazias ao conjunto dos próximos estados.
- Complexidade: $O(mn^2)$ para cadeias de comprimento m e autômatos com n estados.

Exemplo

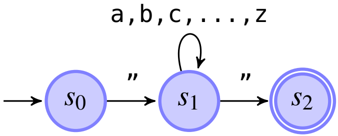

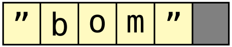

O autômato recebe uma cadeia como entrada e decide aceitá-la ou rejeitá-la

Exemplo

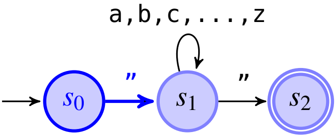

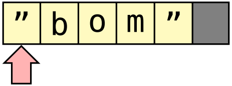

Exemplo

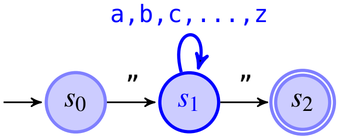

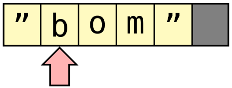

Exemplo

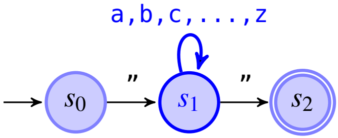

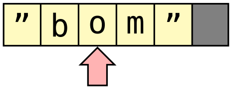

Exemplo

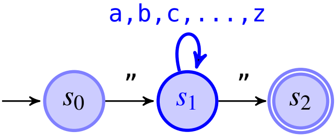

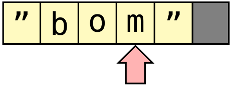

Exemplo

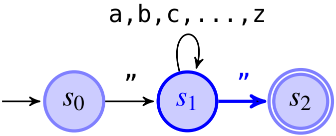

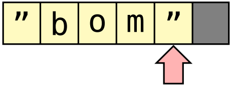

Exemplo

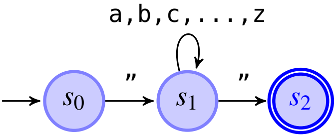

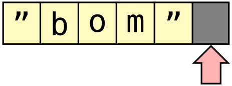

Exemplo

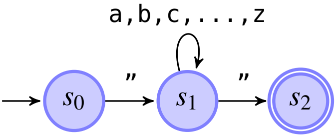

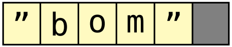

aceita

Fim