Análise léxica

Função, interação com o compilador
Especificação e reconhecimento de tokens
Implementação
Tratamento de erros

Prof. Thiago A. S. Pardo

1

Estrutura geral de um compilador

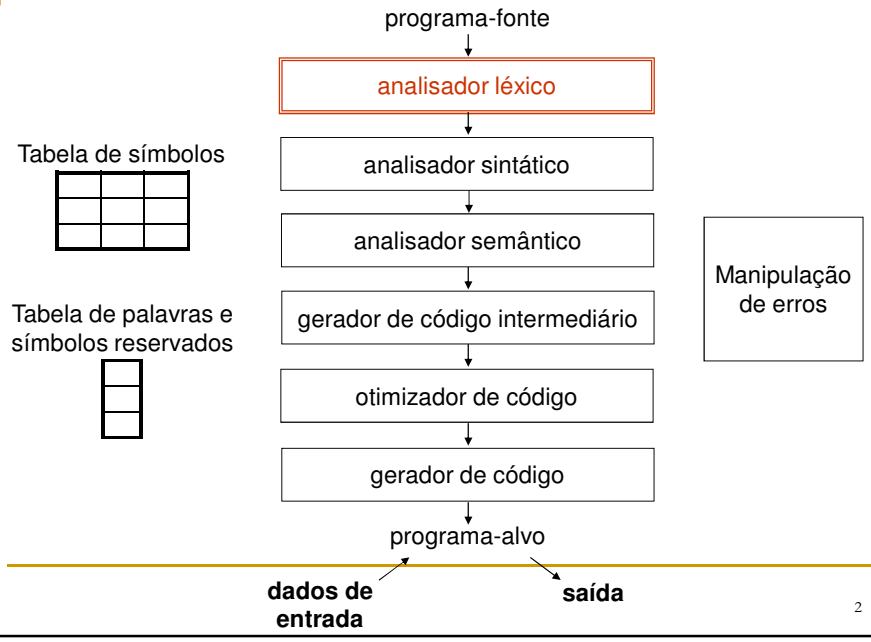

2

Analisador léxico

- Primeira etapa de um compilador
- Função
  - Ler o arquivo com o programa-fonte
  - Identificar os tokens correspondentes
  - Relatar erros (de forma muito limitada)
- Exemplos de tokens
  - Identificadores
  - Palavras reservadas e símbolos especiais
  - Números

3

Exemplo

- x:=y*2;

Cadeia	Token
x	id
:=	simb_atrib
y	id
*	simb_mult
2	num
;	simb_pv

4

Exemplo: usando códigos numéricos

- x:=y*2;

Token	Código
id	1
num	2
simb_mult	3
simb_atrib	4
simb_pv	5

Cadeia	Token
x	1
:=	4
y	1
*	3
2	2
;	5

5

Exemplo

```
program p;
var x: integer;
begin
    x:=1;
    while (x<3) do
        x:=x+1;
end.
```

6

Exemplo

```
program p;
var x: integer;
begin
    x:=1;
    while (x<3) do
        x:=x+1;
end.
```

Cadeia	Token
program	simb_program
p	id
;	simb_pv
var	simb_var
x	id
:	simb_dp
integer	simb_tipo
;	simb_pv
begin	simb_begin
x	id
:=	simb_atrib
1	num
;	simb_pv
while	simb_while
(	simb_apar

x	id
<	simb_menor
3	num
)	simb_fpar
do	simb_do
x	id
:=	simb_atrib
x	id
+	simb_mais
1	num
;	simb_pv
end	simb_end
.	simb_p

7

Analisador léxico

- Em geral, subordinado ao analisador sintático
  - Sub-rotina do analisador sintático: a cada chamada, o analisador léxico retorna para o analisador sintático uma cadeia lida e o token correspondente
- O analisador sintático combina os tokens e verifica a boa formação (sintaxe) do programa-fonte usando a gramática da linguagem

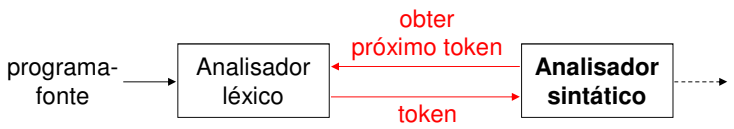

8

Analisador léxico

- Há necessidade dessa interação com o analisador sintático?
  - Não se poderia pré-processar o arquivo todo e produzir um "tabelão" com os tokens?

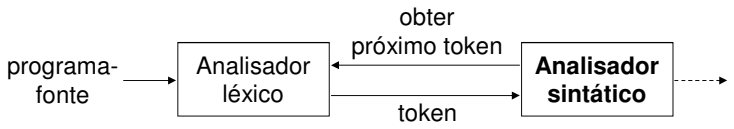

9

Por que separar o analisador léxico do sintático?

10

Por que separar o analisador léxico do sintático?

- Modularização
- Projeto mais simples de cada etapa
- Maior eficiência de cada processo: possibilidade de uso de técnicas específicas e métodos de otimização locais
- Maior portabilidade: especificidades da linguagem de programação podem ser resolvidas na análise léxica
- Facilidade de manutenção
- É mais fácil para o analisador léxico separar identificadores de palavras reservadas

11

Outras funções do analisador léxico

- Consumir comentários e caracteres não imprimíveis (espaço em branco, tabulação, código de nova linha)
  - Se a gramática fosse se responsabilizar por isso, ela seria demasiadamente complicada
    - Por quê?
- Possível manipulação da tabela de símbolos
- Relacionar as mensagens de erro emitidas pelo compilador com o programa-fonte
  - Deve-se manter contagem do número de linhas
- Diagnóstico e tratamento de erros

12

Erros léxicos

- Erros possíveis de serem checados nessa etapa
  - Símbolo não pertencente ao conjunto de símbolos terminais da linguagem: @
  - Identificador mal formado: j@, 1a
  - Tamanho do identificador: minha_variável_para_...
  - Número mal formado: 2.a3
  - Tamanho excessivo do número: 5555555555555555
  - Fim de arquivo inesperado (comentário não fechado): {...
  - Char ou string mal formados: ‘a, “hello world
- São limitados os erros detectáveis nessa etapa
  - Visão local do programa-fonte, sem contexto

fi (a>b) then...

13

Projeto do analisador léxico

- É desejável que se usem notações formais para especificar e reconhecer a estrutura dos tokens que serão retornados pelo analisador léxico
  - Evitam-se erros
  - Mapeamento mais consistente e direto para o programa de análise léxica
- Notações
  - Gramáticas ou expressões regulares: especificação de tokens
  - Autômatos finitos: reconhecimento de tokens

14

Expressões regulares

- Determinam conjuntos de cadeias válidas
  - Linguagem
- Exemplos
  - Identificador: letra (letra | dígito)*
  - Número inteiro sem sinal: dígito+
  - Número inteiro com sinal: (+ | -) dígito+

15

Autômatos finitos

- Modelos matemáticos
  - Conjunto de estados S
  - Conjunto de símbolos de entrada Σ
  - Funções de transição que mapeiam um par estado-símbolo de entrada em um novo estado
  - Um estado inicial s_0
  - Um conjunto de estados finais F para aceitação de cadeias
- Reconhecimento de cadeias válidas
  - Uma cadeia é reconhecida se existe um percurso do estado inicial até um estado final

16

Exemplo

- S={0,1,2,3}, Σ={a,b}, s_0=0, F={3}

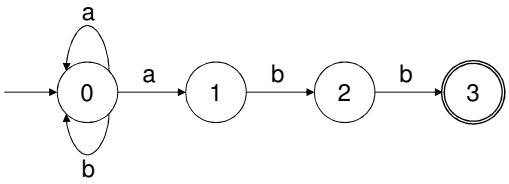

Quais cadeias esse autômato aceita?

(a | b)*abb

Exemplo

- Representação em tabela de transição
  - Vantagem: elegância e generalidade
  - Desvantagem: pode ocupar grande espaço quando o alfabeto de entrada é grande; processamento mais lento

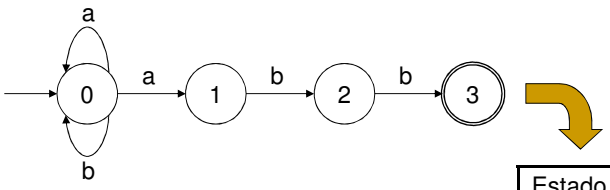

Estado	Símbolo de entrada	
	a	b
0	{0,1}	{0}
1	---	{2}
2	---	{3}

Execução do autômato

- Se autômato determinístico (i.e., não há transições λ e, para cada estado s e símbolo de entrada a, existe somente uma transição possível), o seguinte algoritmo pode ser aplicado

```
s:=s0
c:=próximo_caractere()
enquanto (c<>eof) faça
        s:=transição(s,c)
        c:=próximo_caractere()
fim
se s for um estado final
    então retornar "cadeia aceita"
    senão retornar "falhou"
```

19

Exemplo de execução do autômato

```
s:=s0
c:=próximo_caractere()
enquanto (c<>eof) faça
        s:=transição(s,c)
        c:=próximo_caractere()
fim
se s for um estado final
    então retornar "cadeia aceita"
    senão retornar "falhou"
```

Estado	Símbolo de entrada	
	a	b
0	{1}	{0}
1	---	{2}
2	---	---

S={0,1,2}, Σ={a,b}, s_0=0, F={2}

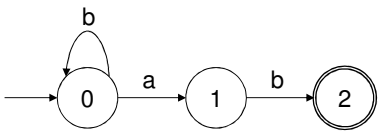

Reconhecer cadeia bab

20

Execução do autômato

- Se autômato não determinístico, pode-se transformá-lo em um autômato determinístico
- Para a aplicação em compiladores, em geral, é muito simples construir um autômato determinístico

Execução do autômato

- Opção: incorporação das transições no código do programa
  - Tabela de transição não é mais necessária

```
s:=s0
enquanto (verdadeiro) faça
    c:=próximo_caractere()
    case (s)
        0: se (c=a) então s:=1
           senão se (c=b) então s:=0
           senão retornar "falhou"
        1: se (c=b) então s:=2
           senão retornar "falhou"
        2: se (c=eof) então retornar "cadeia aceita"
           senão retornar "falhou"
fim
```

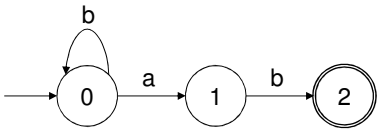

Execução do autômato

- Solução *ad hoc*

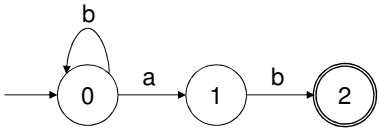


```
c:=próximo_caractere()
se (c='b') então
        c:=próximo_caractere()
        enquanto (c=b) faça
                c:=próximo_caractere()
        se (c='a') então
                c:=próximo_caractere()
                se (c='b') e (acabou cadeia de entrada) então retornar "cadeia aceita"
                senão retornar "falhou"
        senão retornar "falhou"
senão se (c='a') então
        c:=próximo_caractere()
        se (c='b') e (acabou cadeia de entrada) então retornar "cadeia aceita"
        senão retornar "falhou"
senão retornar "falhou"
```

23

Tokens de um programa

- Exemplos de tokens possíveis
  - Identificadores: x, y, minha_variável, meu_procedimento
  - Palavras reservadas e símbolos especiais: while, for, :=, <>
  - Números inteiros e reais
- Não basta identificar o token, deve-se retorná-lo ao analisador sintático junto com a cadeia correspondente
  1. Concatenação da cadeia conforme o autômato é percorrido
  2. Associação de ações semânticas aos estados finais do autômato
- Às vezes, para se decidir por um token, tem-se que se ler um caractere a mais, o qual deve ser devolvido à cadeia de entrada depois

24

Tokens de um programa

- Autômato para os símbolos := e :

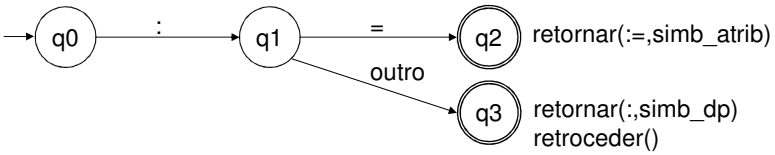

25

Tokens de um programa

- Exercício: autômato para operadores relacionais >, >=, <, <=, = e <>

26

Tokens de um programa

- Exercício: autômato para operadores relacionais >, >=, <, <=, = e <>

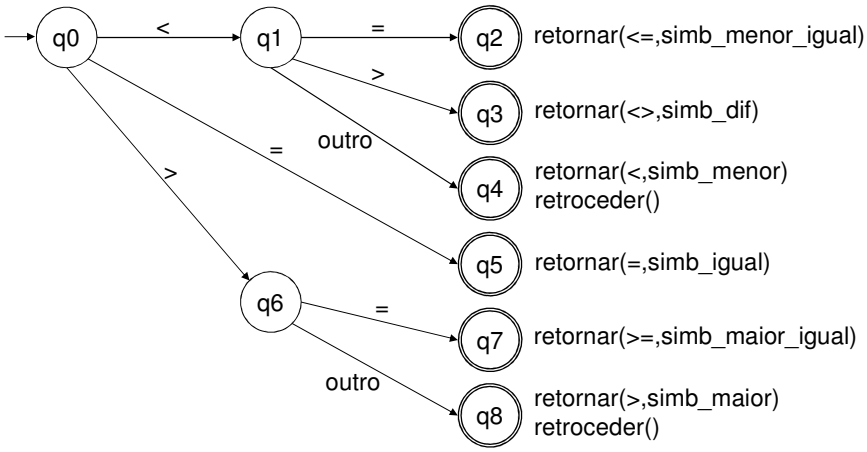

Tokens de um programa

- Autômato para identificadores: letra seguida de qualquer combinação de letras e dígitos

Tokens de um programa

- Autômato para identificadores: letra seguida de qualquer combinação de letras e dígitos

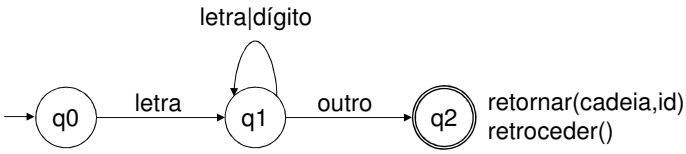

29

Tokens de um programa

- Autômato para palavras reservadas: while, if, for, array, etc.
- Opções
  - Fazer um autômato para cada palavra-reservada
    - Trabalhoso e ineficiente
  - Deixar que o autômato para identificadores reconheça as palavras reservadas e, ao final, verifique na tabela de palavras reservadas se se trata de uma palavra reservada
    - Simples e elegante

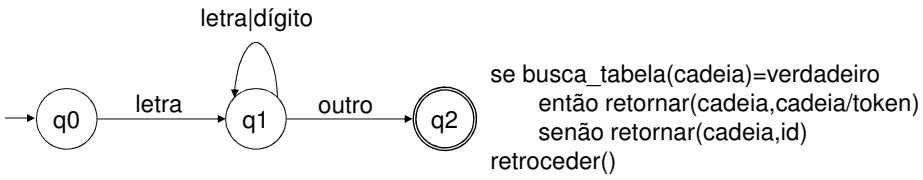

30

Tokens de um programa

- Autômato para consumir caracteres não imprimíveis: espaços em branco, tabulações e códigos de nova linha
  - O analisador léxico não deve produzir tokens para esses símbolos

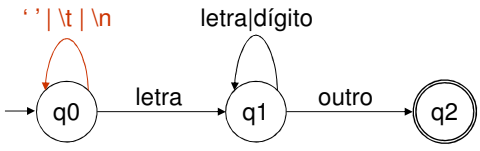


```
se busca_tabela(cadeia)=verdadeiro
      então retornar(cadeia,cadeia/token)
      senão retornar(cadeia,id)
retroceder()
```

31

Tokens de um programa

- Exercício
  - Construir autômatos para se reconhecer
    - Números inteiros com e sem sinal: 5, -1, 100
    - Números reais: 3.11, 0.1

32