

Compiladores

Aula 04: Análise Léxica: Conceitos, FLEX e Pascal

Prof. Aléssio Miranda Júnior
alessio@cefetmg.br

CEFET-MG - Campus Timoteo
Dep. Engenharia de Computação

Março de 2026

- 1 Objetivos
- 2 1. Estrutura de um Compilador
- 3 2. Definição de Análise Léxica
- 4 3. Tokens, Padrões e Lexemas
- 5 4. Expressões Regulares
- 6 5. Implementação Manual do Scanner
- 7 6. Tabela de Símbolos
- 8 7. A Árvore Sintática Abstrata (AST)
- 9 8. Transição e Automação (JFlex)
- 10 Referências

- Compreender a posição da análise léxica na estrutura do compilador.
- Definir os conceitos fundamentais: tokens, padrões e lexemas.
- Conhecer as **Expressões Regulares** como formalismo para tokens.
- Aprender a usar o **JFlex** (gerador léxico) com **Java**.
- Construir passo a passo um **analisador léxico para Pascal simplificado**.
- Integrar o lexer gerado com código Java.

1. Estrutura de um Compilador

O processo de compilação é dividido em duas grandes fases:

Fase de Análise (Front-End)

1. Programa Fonte
2. **Analizador Léxico**
3. Analisador Sintático
4. Analisador Semântico

Fase de Síntese (Back-End)

5. Gerador de Código Intermediário
6. Otimizador de Código
7. Gerador de Código Objeto
8. Programa Objeto

Posição do Analisador Léxico

É a **primeira fase** do compilador, fazendo a interface direta com o código-fonte.

O que é Análise Léxica?


Definição Ampla

Análise léxica é o processo de analisar a entrada de linhas de caracteres (tal como o código-fonte de um programa de computador) e produzir uma sequência de símbolos chamados "**símbolos léxicos**" (lexical tokens), ou somente "**símbolos**" (tokens), que podem ser manipulados mais facilmente por um parser (leitor de saída).

Verificação de Alfabeto

A Análise léxica é a forma de verificar determinado alfabeto. Quando analisamos uma palavra, podemos definir se existe ou não algum caractere que não faz parte do nosso alfabeto (ou um alfabeto inventado). **É a primeira etapa de um compilador**, vindo logo antes da análise sintática.

Fluxo de Dados: Léxico e Sintático



Nota: Este é o fluxo básico do léxico.

2. Definição de Análise Léxica

A análise léxica é a **primeira etapa** de um compilador. Suas principais funções são:

- **Leitura da entrada:** Lê o fluxo de caracteres do código-fonte.
- **Agrupamento:** Produz uma sequência de **tokens** (símbolos léxicos).
- **Filtragem:** Remove espaços em branco, quebras de linha e comentários.
- **Verificação:** Valida se os caracteres pertencem ao alfabeto da linguagem.
- **Relatório de erros:** Informa caracteres inválidos (erros léxicos).

Atenção

O analisador léxico **não verifica estrutura gramatical** — isso é papel do analisador sintático.

3. Tokens, Padrões e Lexemas

É essencial distinguir estes três conceitos fundamentais:

Token

Par $\langle \text{nome}, \text{atributo} \rangle$. O **nome** é um símbolo abstrato; o **atributo** carrega informações extras.

Ex.: $\langle \text{id}, \text{"taxa"} \rangle$, $\langle \text{num}, 100 \rangle$, $\langle \text{if} \rangle$

Lexema

A **sequência real de caracteres** no código-fonte que casa com o padrão de um token.

Ex.: taxa, 100, if

Padrão (Pattern)

A **regra** (expressão regular) que descreve o conjunto de lexemas de um token.

Ex.: $[a-zA-Z][a-zA-Z0-9]^*$ para identificadores.

Estrutura Básica

```
program Exemplo1;  
var  
    x, y: integer;  
begin  
    x := 10;  
    y := 20;  
    if x < y then  
        writeln('Menor');  
end.
```

Repetição

```
program Fatorial;
var
  n, i, res: integer;
begin
  n := 5; i := 1; res := 1;
  while i <= n do
  begin
    res := res * i;
    i := i + 1;
  end;
  writeln(res);
end.
```

Exemplo de Classificação de Tokens

Entrada: `if (a < 100) x := 5;`

Lexema	Token	Categoria
if	IF	Palavra-chave
(	LPAREN	Símbolo
a	ID, "a"	Identificador
<	LT	Operador
100	NUM, 100	Número
)	RPAREN	Símbolo

Lexema	Token	Categoria
x	ID, "x"	Identificador
:=	ASSIGN	Operador
5	NUM, 5	Número
;	SEMI	Símbolo

O Papel do Scanner na Compilação

O **scanner** (analisador léxico) e o **parser** (analisador sintático) interagem:

Parser $\xrightarrow{\text{getNextToken()}}$ Scanner $\xrightarrow{\text{lê chars}}$ Código-Fonte

- O scanner age **sob demanda** do parser.
- Mantém a **linha atual** para mensagens de erro.
- Consulta e popula a **Tabela de Símbolos**.

Vantagem de separar léxico de sintático

Simplifica o design, permite reutilização e melhora as mensagens de erro.

4. Expressões Regulares (ER)

Utilizadas para descrever os padrões de tokens de forma compacta:

Operações Básicas:

- **Concatenação:** ab (a seguido de b)
- **Alternativa:** $a \mid b$ (a ou b)
- **Kleene:** a^* (zero ou mais a)
- **Positiva:** a^+ (um ou mais a)
- **Opcional:** $a?$ (zero ou um a)
- **Classe:** $[a-z]$ (faixa de chars)
- **Ponto:** $.$ (qualquer char)

Exemplos:

- $[a-zA-Z_]$ — letra ou $_$
- $[0-9]^+$ — inteiro positivo
- $[0-9]^+ \backslash . [0-9]^+$ — real
- $[a-zA-Z_][a-zA-Z0-9_]^*$ — ID
- $"[^"]^*"$ — string literal
- $// [^\n]^*$ — comentário linha

Token	Expressão Regular	Descrição
ID	<code>[a-zA-Z][a-zA-Z0-9_]*</code>	Identificador
INTEGER	<code>[0-9]+</code>	Inteiro
REAL	<code>[0-9]+\.[0-9]+</code>	Real
STRING	<code>'[^']*'</code>	String (aspas simples)
ASSIGN	<code>:=</code>	Atribuição
RANGE	<code>..</code>	Intervalo (1..10)
COMMENT	<code>{[^}]*}</code>	Comentário {...}
WS	<code>[\t\n\r]+</code>	Espaços (ignorar)

ER → AF: Exemplo 1 (Identificadores)

Expressão Regular: $[a-zA-Z][a-zA-Z0-9]^*$



- **S0** → **S1**: Transição ao ler uma letra.
- **S1**: Estado final (aceitação). Continua em S1 para qualquer letra ou dígito.

Expressão Regular: $[0-9]^+$



- Garante que pelo menos um dígito seja lido (+).
- O estado S_1 consome todos os dígitos subsequentes.

Expressão Regular: :=



- Exemplo de lexema fixo (sem repetição).
- O scanner deve ver o caractere `:` e logo após obrigatoriamente o `=`.

5. Implementando um Scanner Manualmente

Como transformamos um DFA em código Java? Usamos um laço de leitura e estruturas de decisão!

```
public Token nextToken() {  
    // 1. Pular espaços em branco e comentarios  
    pularEspacos();  
  
    char c = readChar();  
  
    // 2. Identificar o estado inicial  
    if (Character.isLetter(c)) {  
        return lerIdentificadorOuPalavraChave(c);  
    } else if (Character.isDigit(c)) {  
        return lerNumero(c);  
    } else if (c == ':' ) {  
        // Lookahead: espiar o proximo char  
        if (peek() == '=' ) {  
            readChar(); // consome o '='  
            return new Token(TokenType.ASSIGN, " :=");  
        }  
        return new Token(TokenType.COLON, " :");  
    }  
    // ...  
}
```

A implementação manual exige um controle rigoroso do ponteiro de leitura:

- **readChar()**: consome o caractere atual e avança.
- **peek()**: espia o próximo caractere **sem consumi-lo** (essencial para operadores como `:=`, `<=`).
- **Atributos**: posicao, linha, coluna.

Dica para o TP

Para consolidar a lógica dos autômatos, implementaremos o laço de repetição e as transições de estado "na unha". Isso desenvolve uma base algorítmica fortíssima!

6. Tabela de Símbolos

A Tabela de Símbolos (T.S.) armazena informações sobre os identificadores encontrados no código.

O que guardar?

- Nome (lexema)
- Categoria (vairável, constante, função)
- Tipo (integer, boolean)
- Escopo e Endereço

Implementação:

- Geralmente uma **Tabela Hash**.
- Busca rápida $O(1)$.
- Palavras reservadas podem ser inseridas previamente.

Tabela de Símbolos: Exemplo Prático

Para o trecho: `var saldo: integer;`

Lexema	Token	Tipo	Escopo
integer	T_INTEGER	—	global (keyword)
saldo	ID	integer	local

```
// Estrutura basica em Java  
Map<String, Symbol> tabela = new HashMap<>();  
tabela.put("saldo", new Symbol("saldo", TokenType.ID, "integer"));
```

7. Para onde vão os Tokens? A AST

O Analisador Sintático (Parser) solicita os tokens ao Lexer e constrói uma **Árvore Sintática Abstrata (AST)**.

- A AST é a representação em memória do seu programa.
- Descarta detalhes sintáticos irrelevantes e foca na **estrutura lógica**.
- Base para análise semântica e geração de código.

Código: $x := 10 + 5 \rightarrow \text{Atribuição}(\text{ID}(x), \text{Soma}(\text{Num}(10), \text{Num}(5)))$

Na O.O. (Java), implementamos a AST usando o padrão **Composite**.

- **AstNode**: Classe base abstrata.
- **Expression**: Nós que representam valores (soma, números).
- **Command**: Nós que representam ações (if, while, atribuição).

Conexão com o Trabalho Prático

Entender como os tokens formam essa estrutura é vital para a Etapa 1 do seu roteiro!

8. Geradores de Analisadores Léxicos

Na prática profissional, utilizamos ferramentas chamadas **Geradores Léxicos** (como Lex, Flex ou **JFlex**).

- **Como funciona?** Você define as regras via **Expressões Regulares**.
- A ferramenta gera automaticamente o código Java que implementa o DFA.
- **Vantagem:** Produtividade e robustez.

Estrutura JFlex

Dividido em 3 seções permanentes: `/* Código Java */ %%` `/* Opcoes e Macros */ %%`
`/* Regras */`

Exemplo Pascal no JFlex (Resumido)

```
/* Opcoes */
%class PascalLexer
%type Token
%%
/* Regras (Apenas Exemplos) */
"if"      { return new Token(TokenType.IF); }
"program" { return new Token(TokenType.PROGRAM); }
{ID}      { return new Token(TokenType.ID, yytext()); }
{INTEGER} { return new Token(TokenType.INT, yytext()); }
":="      { return new Token(TokenType.ASSIGN); }
```

- **JFlex**: <https://jflex.de> — Documentação oficial do gerador de lexers para Java.
- Wirth, N. *Algorithms + Data Structures = Programs* — referência original do Pascal.
- *The JFlex Manual* ve. 1.9.1 — guia completo de directivas e regras.

Obrigado!

Email: alessio@cefetmg.br

“A análise léxica é o alicerce — sem ela, o compilador não enxerga nada.”