Conceitos de Linguagens de Programação

Aula 04 – Sintaxe e Semântica

Edirlei Soares de Lima

<edirlei@iprj.uerj.br>

Sintaxe e Semântica

- A descrição de uma linguagem de programação envolve dois aspectos principais:
  - **Sintaxe:** descreve a forma ou estrutura de expressões, comandos e unidades de programa. É composto por um conjunto de regras que determinam quais construções são corretas.
  - **Semântica:** descreve o significado das expressões, comandos e unidades de programa. Define como as construções da linguagem devem ser interpretadas e executadas.

- **Exemplo** – IF na linguagem C:
  - Sintaxe: `if (<expressão>) <instrução>`
  - Semântica: se o valor atual da expressão for verdadeiro, a instrução incorporada será selecionada para execução.

Sintaxe e Semântica – Exemplo

- Analise o seguinte código em linguagem C e verifique se existem erros:

```
int j=0, conta, V[10];
float i@;
conta = '0'
for (j=0, j<10; j++
{
  V[j] = conta++;
}
```

- O compilador tem a responsabilidade de reportar erros! É necessário algum recurso para identificá-los.

Sintaxe e Semântica – Exemplo

- Esses erros são verificados e diferenciados durante as fases de análise da compilação:

- **Análise Léxica:** reúne as unidades léxicas (tokens) do programa:
  - int, j, =, 0, conta, for, (, <, int, ++...
  - **Erro:** i@

- **Análise Sintática:** realiza a combinação de tokens que formam o programa:
  - comando_for → for (expr1; expr2; expr3) {comandos}
  - **Erros:** ; for(j=0, ...)

- **Análise Semântica:** verifica a adequação do uso:
  - Tipos semelhantes em comandos (atribuição, por exemplo), uso de identificadores declarados...
  - **Erro:** conta = '0'

Processo de Compilação

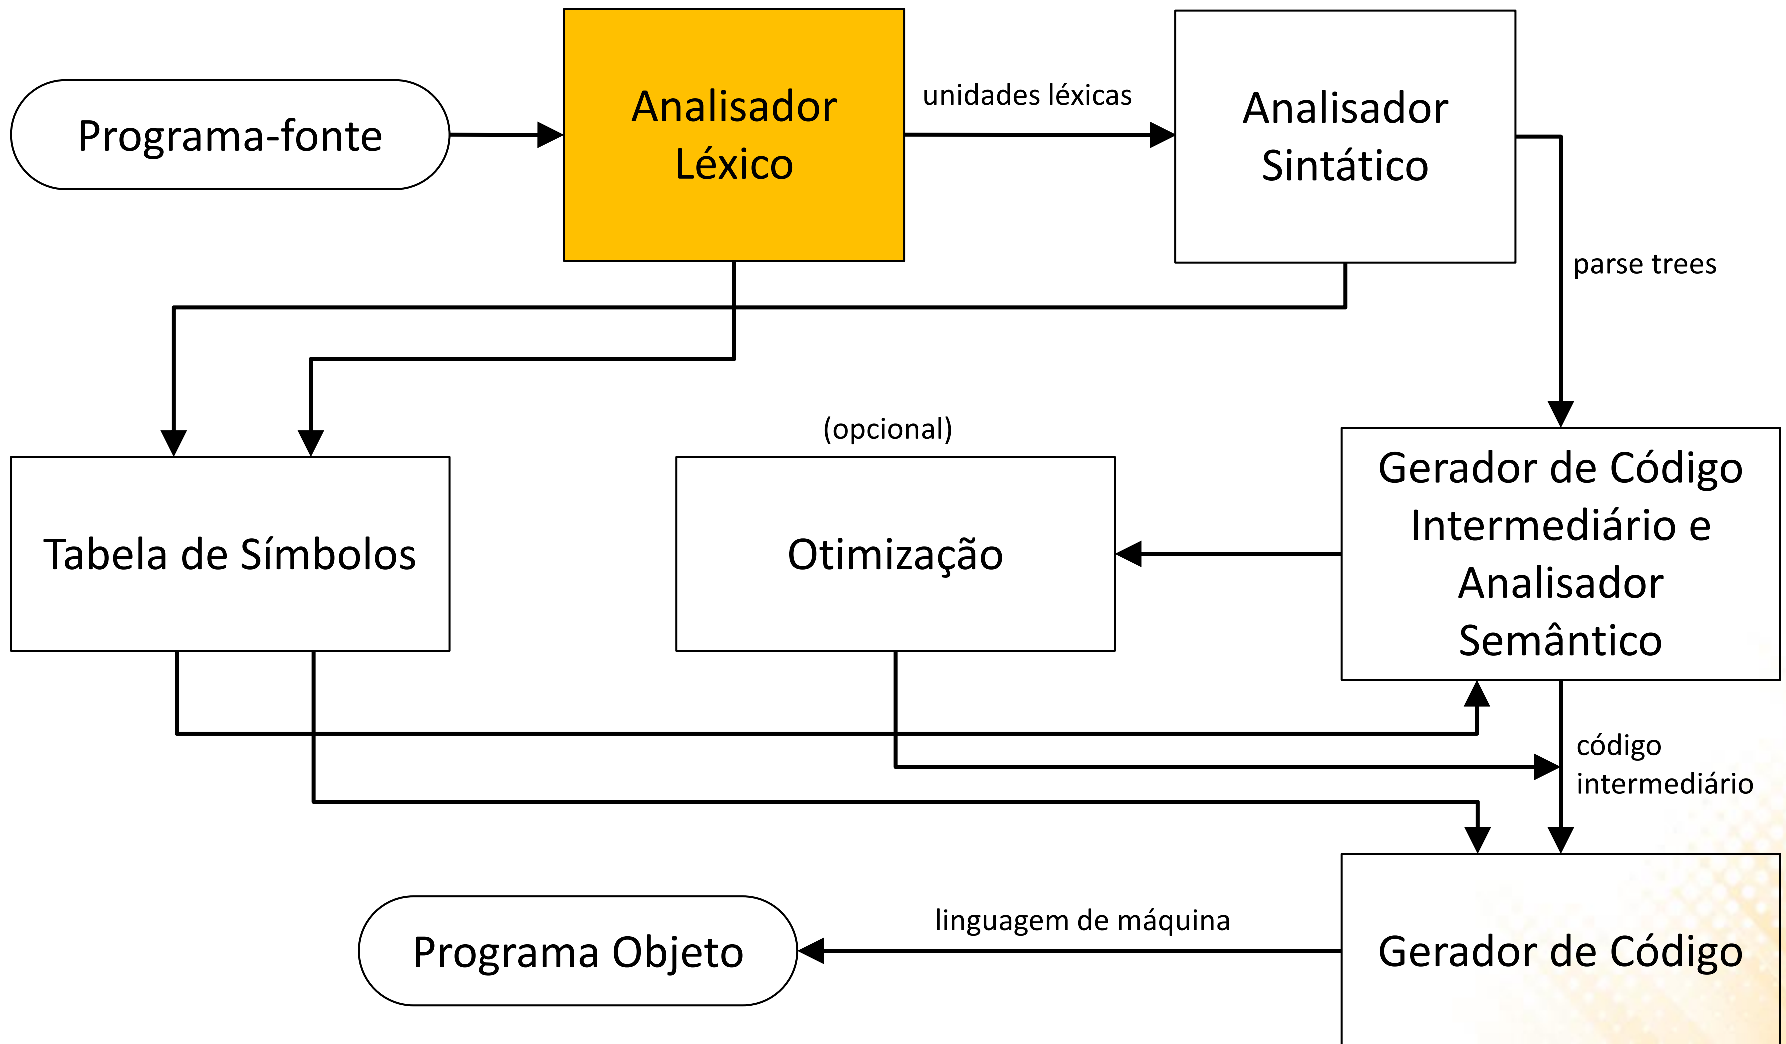

Análise Léxica

- A análise léxica é responsável por ler o código fonte e separá-lo em partes significativas, denominadas tokens, instanciadas por átomos.

```
int gcd(int a, int b)
{
  while (a != b) {
    if (a > b) a -= b;
    else b -= a;
  }
  return a;
}
```

```
[int] [gcd] [(] [int] [a] [,] [int] [b] [)] [{] [while] [(] [a]
[!=] [b] [)] [{] [if] [(] [a] [>] [b] [)] [a] [-=] [b] [;] [else]
[b] [-=] [a] [;] [}] [return] [a] [;] [}]
```

Análise Léxica

- A análise léxica pode ser feita através de **autômatos finitos** ou **expressões regulares**.
  - Um autômato finito é uma máquina de estados finitos formada por um conjunto de estados (um estado inicial e um ou mais estados finais);

- Simulador: **JFLAP** (http://www.jflap.org/jflaptmp/)
  - Exemplo de autômato para reconhecer atribuições entre variáveis:

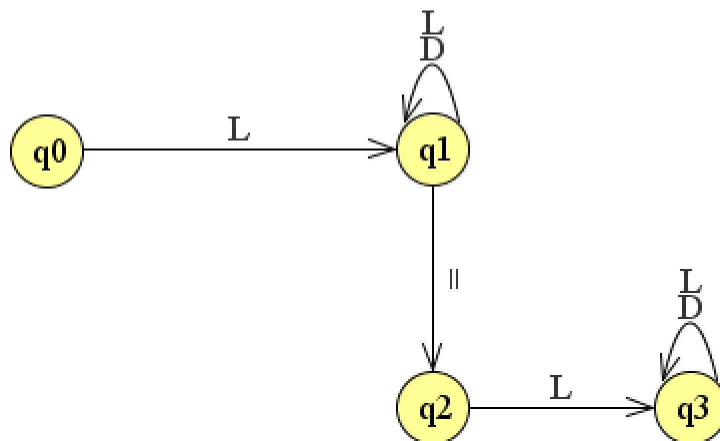

L → a..z
D → 0..9
= → atribuição

Análise Léxica

- Simulador: **JFLAP – Exemplos:**
  - Cadeia de caracteres a, b, c;
  - Números inteiros (com ou sem sinal);
  - Números reais (com ou sem sinais);
  - Identificador;
  - Comparação (>, >=, <, <=, !=) entre dois identificadores;
  - Atribuição (=) entre dois identificadores;

Análise Léxica

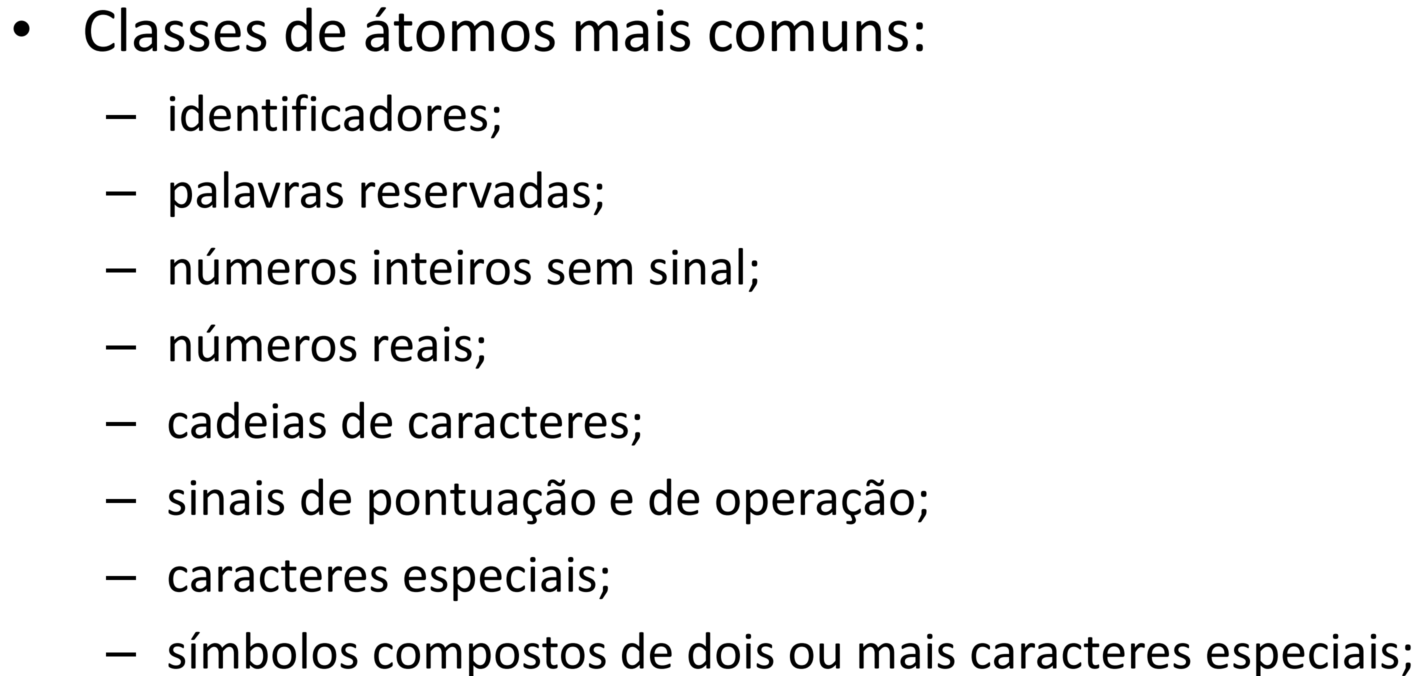

- Classes de átomos mais comuns:
  - identificadores;
  - palavras reservadas;
  - números inteiros sem sinal;
  - números reais;
  - cadeias de caracteres;
  - sinais de pontuação e de operação;
  - caracteres especiais;
  - símbolos compostos de dois ou mais caracteres especiais;

Processo de Compilação

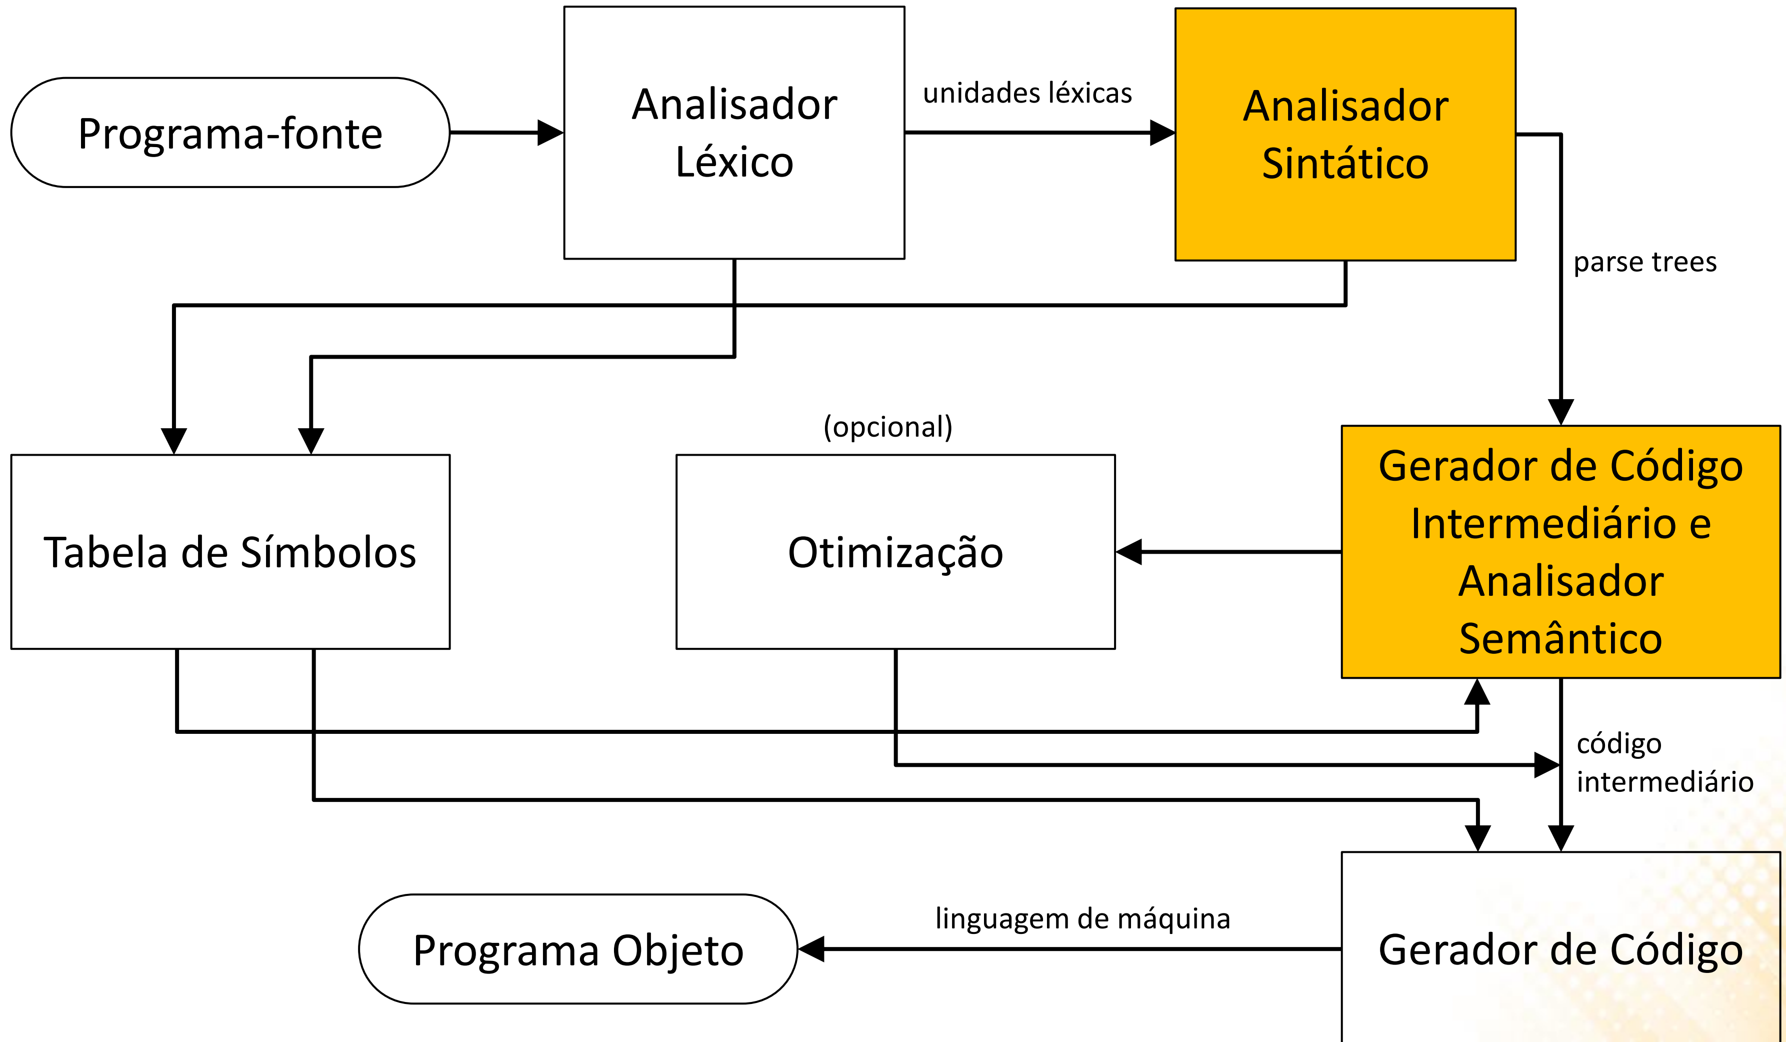

Análise Sintática e Semântica

- A **análise sintática** realiza verificação da formação do programa.
  - **Gramáticas livres de contexto**;

```
<atribuição> → <var> = <expressão>
```

```
total = sub1 + sub2
```

- A **análise semântica** realiza a verificação do uso adequado da gramática.
  - Por exemplo, verificando se os identificadores estão sendo usados de acordo com o tipo declarado;

Descrevendo a Sintaxe

- Linguagens, sejam naturais ou artificiais, são **conjuntos de sequências de caracteres de algum alfabeto**, onde:
  - Uma **sentença** é uma sequência de caracteres sobre um alfabeto;
  - Uma **linguagem** é um conjunto de sentenças;
  - Um **lexema** é a unidade sintática de menor nível em uma linguagem (exemplo: *, sum, begin);
  - Um **token** é uma categoria de lexemas (exemplo: identificador, números, caracteres, etc.);
- Um programa pode ser visto como sendo uma **sequência de lexemas**.

Descrevendo a Sintaxe

- Exemplo:

```
index = 2 * count + 17;
```

Lexemas	**Tokens**
index	identificador
=	sinal_atribuicao
2	int_literal
*	mult_op
cont	identificador
+	soma_op
17	int_literal
;	ponto_e_virgula

Descrevendo a Sintaxe

- As linguagens podem ser formalmente definidas de duas maneiras:

- **Reconhecedores:**
  - Um dispositivo de reconhecimento lê uma cadeia de entrada de uma linguagem e decide se esta pertence ou não a linguagem;
  - Exemplo: Analisador sintático de um compilador.

- **Geradores:**
  - Dispositivo que gera uma sentença da linguagem sempre que acionado;
  - Pode-se determinar se a sintaxe de uma determinada sequência esta correta comparando-a a estrutura de um gerador.

Métodos Formais para Descrever Sintaxe

- **Sintaxe** → definida formalmente através de uma gramática.

- **Gramática** → conjunto de definições que especificam uma sequência válida de caracteres.

- Duas classes de gramáticas são úteis na definição formal das gramáticas:
  - Gramáticas livres de contexto;
  - Gramáticas regulares.

Métodos Formais para Descrever Sintaxe

- **Forma de Backus-Naur (1959) – BNF**
  - Inventada por John Backus para descrever o Algol 58; modificada por Peter Naur para descrever o Algol 60. É considerada uma gramática livre de contexto.

- A BNF é a forma mais popular de se descrever concisamente a sintaxe de uma linguagem.

- Embora simples é capaz de descrever a grande maioria das sintaxes das linguagens de programação.

Forma de Backus-Naur (BNF)

- Na BNF, abstrações são usadas para representar classes de estruturas sintáticas.

```
<atribuição> → <var> = <expressão>
```

(LHS) (RHS)

- Uma abstração é definida através de uma **regra** ou **produção**. Esta é formada por:
  - **Lado esquerdo (LHS)** – abstração a ser definida (símbolo não-terminal).
  - **Lado direito (RHS)** – definição da abstração, composta por símbolos, lexemas e referências a outras abstrações.

- Símbolos e lexemas são denominados símbolos terminais.

Forma de Backus-Naur (BNF)

- < > indica um **não-terminal** (termo que precisa ser expandido);
- Símbolos não cercados por < > são **terminais**;
  - Eles são representativos por si. Exemplo: if, while, (, =
- O símbolo → significa **é definido como**;
- Os símbolos cercados por {} indica que o termo **pode ser repetido n vezes** (inclusive nenhuma);
- O símbolo | significa **or** e é usado para separar alternativas.

Forma de Backus-Naur (BNF)

- Uma descrição BNF ou Gramática de uma linguagem é definida por um **conjunto de regras**.

- Símbolos não-terminais podem ter **mais de uma definição** distinta, representando duas ou mais formas sintáticas possíveis na linguagem.

  – Regras diferentes:

```
<inst_if> → if ( <expr_logica> ) <inst>
<inst_if> → if ( <expr_logica> ) <inst> else <inst>
```

  – Mesa regra:

```
<inst_if> → if ( <expr_logica>) <inst>
          | if ( <expr_logica>) <inst> else <inst>
```

Forma de Backus-Naur (BNF)

- Uma regra é **recursiva** se o LHS aparecer no RHS.

- **Exemplo** – definição de listas de identificadores:

```
<ident_lista> → identificador
              | identificador, <ident_lista>
```

- <ident_lista> é definido como um único símbolo ou um símbolo seguido de virgula e de outra instancia de <ident_lista> .

Gramáticas e Derivações

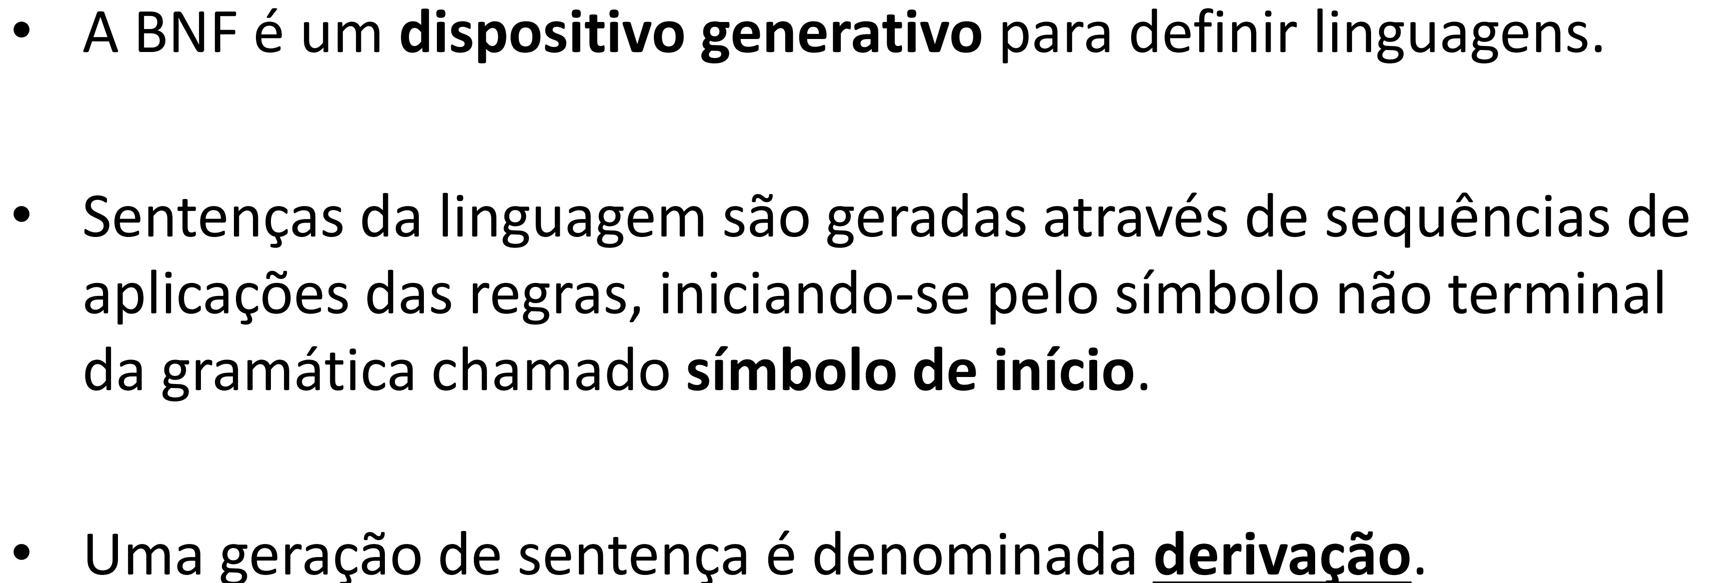

- A BNF é um **dispositivo generativo** para definir linguagens.

- Sentenças da linguagem são geradas através de sequências de aplicações das regras, iniciando-se pelo símbolo não terminal da gramática chamado **símbolo de início**.

- Uma geração de sentença é denominada **derivação**.

Gramáticas e Derivações

- Exemplo de **gramática** de uma linguagem simples:

```
<programa> → begin <lista_inst> end
<lista_inst> → <inst> ; <lista_inst>
             | <inst>
<inst> → <var> = <expressao>
<var> → A | B | C
<expressao> → <var> + <var>
            | <var> - <var>
            | <var>
```

Gramáticas e Derivações

- Exemplo de **derivação** de um programa na linguagem especificada:

```
<programa> => begin <lista_inst> end
           => begin <inst> ; <lista_inst> end
           => begin <var> = <expressão> ; <lista_inst> end
           => begin A = <expressão> ; <lista_inst> end
           => begin A = <var> + <var> ; <lista_inst> end
           => begin A = B + <var> ; <lista_inst> end
           => begin A = B + C ; <lista_inst> end
           => begin A = B + C ; <inst> end
           => begin A = B + C ; <var> = <expressão> end
           => begin A = B + C ; B = <expressão> end
           => begin A = B + C ; B = <var> end
           => begin A = B + C ; B = C end
```

Gramáticas e Derivações

- Cada uma das cadeias da derivação, inclusive <programa>, é chamada de **forma sentencial**.

- No exemplo anterior, o não-terminal substituído é sempre o da extrema esquerda. Derivações que usam essa ordem são chamadas de **derivações à extrema esquerda** (*leftmost derivations*).
  - É possível realizar a derivação a extrema direita;

- A derivação prossegue até que a forma sequencia não contenha nenhum não-terminal.

Gramáticas e Derivações

- Mais um exemplo de gramática:

```
<atribuicao> → <id> = <expr>
<id> → A | B | C
<expr> → <id> + <expr>
       | <id> * <expr>
       | ( <expr> )
       | <id>
```

- Derivando: **A = B * (A + C)**

```
<atribuicao> => <id> = <expr>
             => A = <expr>
             => A = <id> * <expr>
             => A = B * <expr>
             => A = B * ( <expr> )
             => A = B * ( <id> + <expr> )
             => A = B * ( A + <expr> )
             => A = B * ( A + <id> )
             => A = B * ( A + C )
```

Exercícios

Lista de Exercícios 02 – Gramáticas e Derivações

Aplicando as Regras da Gramática

```
<assignment> → ID = <expression> ;

<expression> → <expression> + <term>
             | <expression> - <term>
             | <term>

<term> → <term> * <factor>
       | <term> / <factor>
       | <factor>

<factor> → ( <expression> )
         | ID
         | NUMBER

<ID> → x|y|z

<NUMBER> → 0|1|2|3|4|5|6|7|8|9
```

Aplicando as Regras da Gramática

- **Entrada:**

```
z = (2*x + 5)*y - 7;
```

Analisador Léxico

- **Tokens:**

ID	ASSIGNOP	GROUP	NUMBER	OP	ID	OP	NUMBER	GROUP	OP	ID	OP	NUMBER	DELIM
z	=	(	2	*	x	+	5	)	*	y	-	7	;

Analisador Sintático

Aplicando as Regras da Gramática

```
ID = ( NUMBER * ID + NUMBER ) * ID - NUMBER ;
```

```
<assignment> → ID = <expression> ;

<expression> → <expression> + <term>
             | <expression> - <term>
             | <term>

<term> → <term> * <factor>
       | <term> / <factor>
       | <factor>

<factor> → ( <expression> )
         | ID
         | NUMBER

<ID> → x|y

<NUMBER> → 0|1|2|3|4|5|6|7|8|9
```

parser

```
ken
uce
ift

ift
uce
uce
ift
uce
uce
ift
/sh
uce
uce
```

Aplicando as Regras da Gramática

```
ID = ( NUMBER * ID + NUMBER ) * ID - NUMBER ;
```

```
parser:ID                                 read (shift) first token
       factor                                                reduce
       factor =                                               shift
       FAIL: Can't match any rules (reduce).
       Backtrack and try again
       ID = ( NUMBER                                          shift
       ID = ( factor                                         reduce
       ID = ( term *                                      sh/reduce
       ID = ( term * ID                                       shift
       ID = ( term * factor                                  reduce
       ID = ( term                                           reduce
       ID = ( term +                                          shift
       ID = ( expression + NUMBER                         reduce/sh
       ID = ( expression + factor                            reduce
       ID = ( expression + term                              reduce
```

Aplicando as Regras da Gramática

```
ID = ( NUMBER * ID + NUMBER ) * ID - NUMBER ;
```

```
<assignment> → ID = <expression> ;

<expression> → <expression> + <term>
             | <expression> - <term>
             | <term>

<term> → <term> * <factor>
       | <term> / <factor>
       | <factor>

<factor> → ( <expression> )
         | ID
         | NUMBER

<ID> → x|y

<NUMBER> → 0|1|2|3|4|5|6|7|8|9
```

luce
ift
luce
ift
/sh
luce
luce
ift
luce
ift
luce
luce
ift
luce

Aplicando as Regras da Gramática

```
ID = ( NUMBER * ID + NUMBER ) * ID - NUMBER ;
```

```
ID = ( expression                        reduce
ID = ( expression )                       shift
ID = factor                              reduce
ID = factor *                             shift
ID = term * ID                        reduce/sh
ID = term * factor                       reduce
ID = term                                reduce
ID = term -                               shift
ID = expression -                        reduce
ID = expression - NUMBER                  shift
ID = expression - factor                 reduce
ID = expression - term                   reduce
ID = expression ;                         shift
assignment                               reduce
```

Parse Trees

- As gramaticas descrevem naturalmente parse trees.

- Uma **parse tree** é representação em forma de árvore da derivação, onde:

  - Todo **nó interno** da árvore é um símbolo **não-terminal**;

  - Toda **folha** é rotulada com um símbolo **terminal**;

  - Toda **sub-árvore** descreve uma instância de uma **abstração** na sentença.

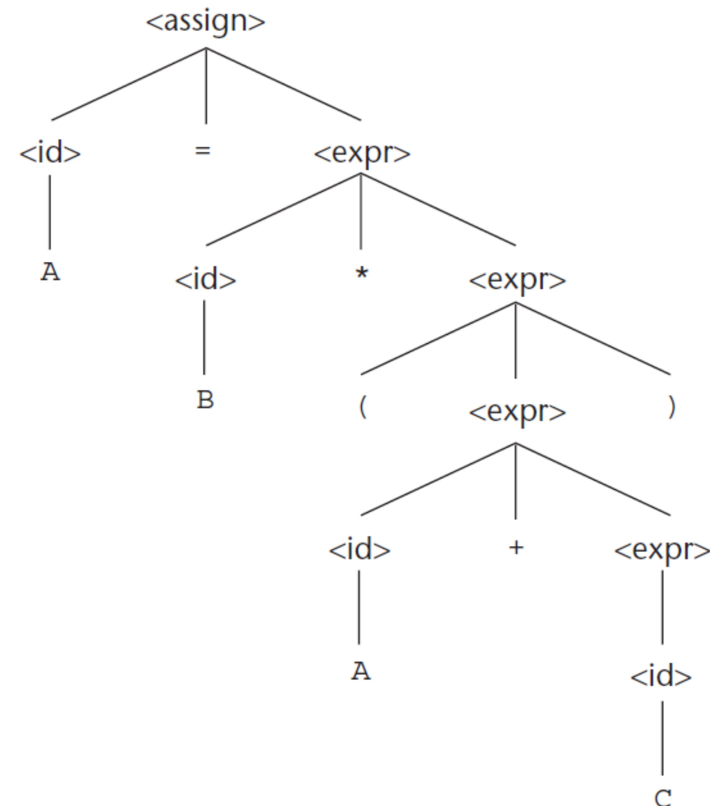

Parse Trees – Exemplo

```
<assign> → <id> = <expr>
<id> → A | B | C
<expr> → <id> + <expr>
       | <id> * <expr>
       | ( <expr> )
       | <id>
```

```
<assign> => <id> = <expr>
         => A = <expr>
         => A = <id> * <expr>
         => A = B * <expr>
         => A = B * ( <expr> )
         => A = B * ( <id> + <expr> )
         => A = B * ( A + <expr> )
         => A = B * ( A + <id> )
         => A = B * ( A + C )
```

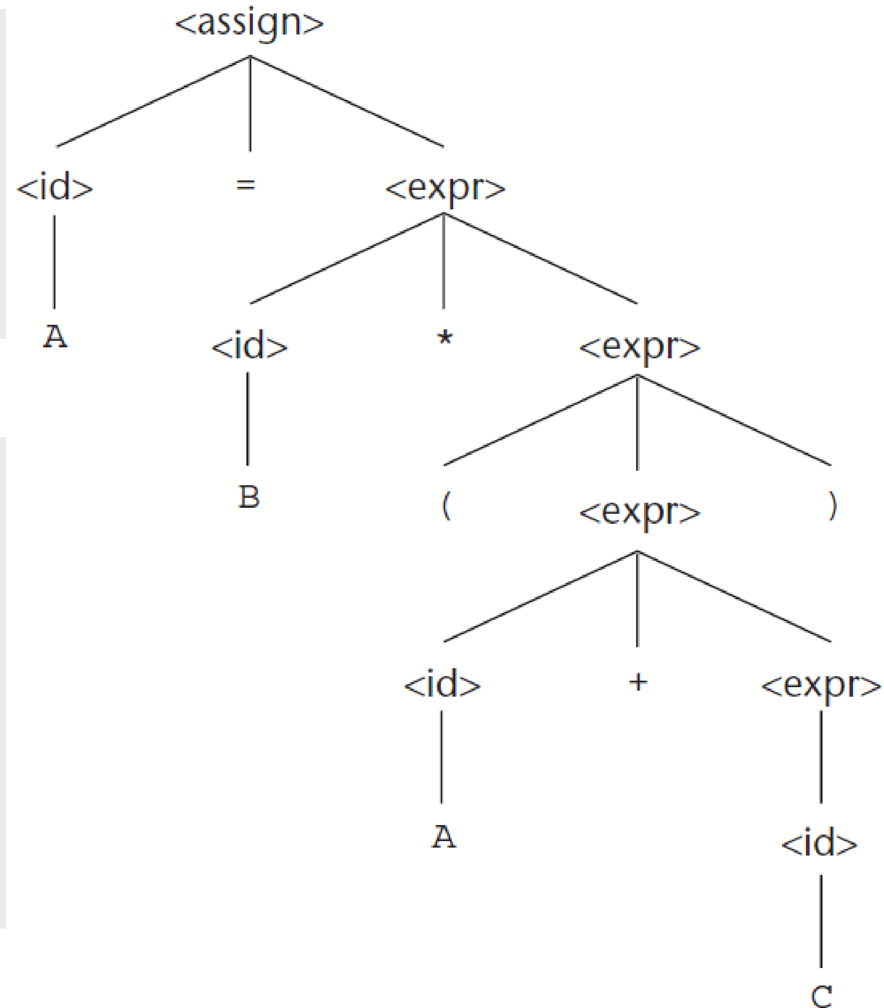

Parse Trees – Processo de Compilação

- Para utilizar uma parse tree para gerar código de máquina, o compilador explora a árvore e gera código conforme ele reconhece sentenças.
- **Busca em profundidade**.

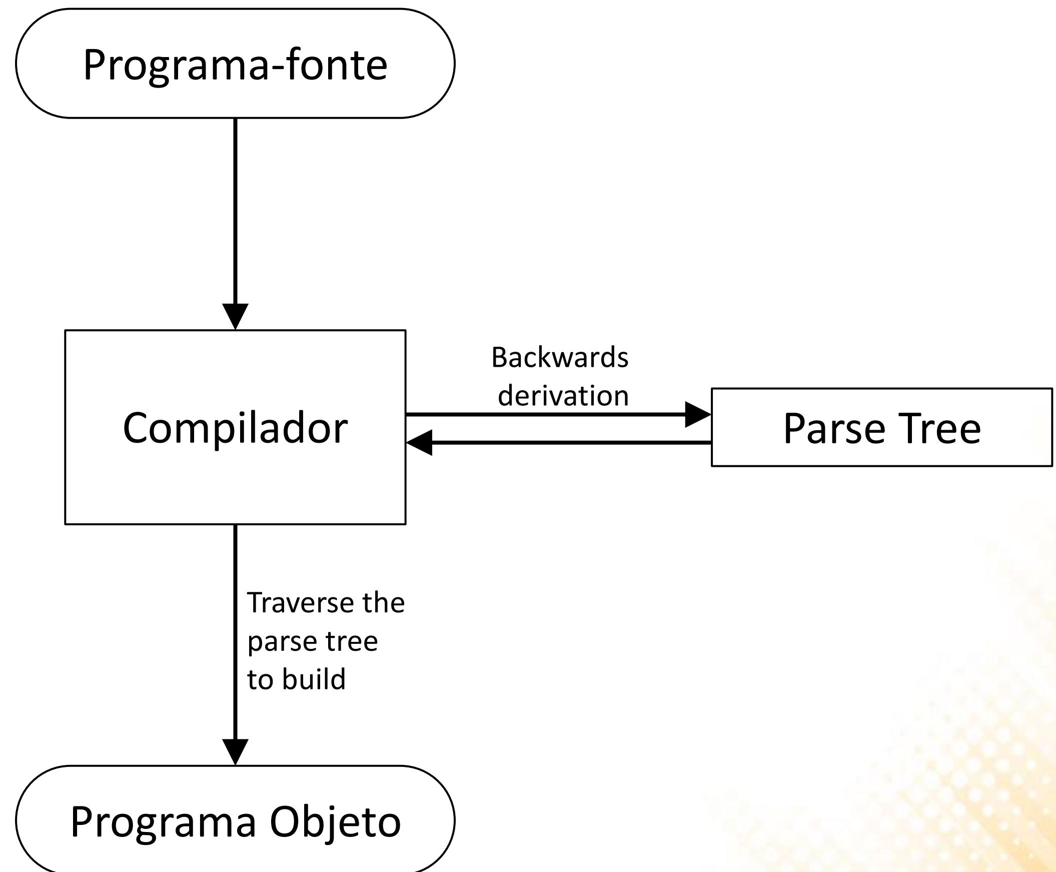

Parse Trees – Exemplo

```
<expr> → <expr> <op> <expr>
        | A | B | C

<op> → * | +
```

A = B + C * A

```
<expr> => <id> = <expr>
       => A = <expr>
       => A = <expr> + <expr>
       => A = <id> + <expr>
       => A = B + <expr>
       => A = B + <expr> * <expr>
       => A = B + <id> * <expr>
       => A = B + C * <expr>
       => A = B + C * <id>
       => A = B + C * A
```

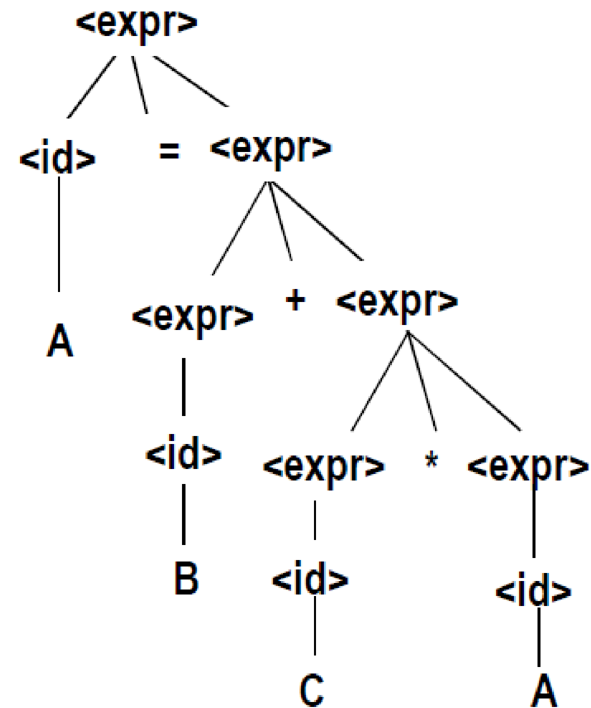

Parse Trees – Exemplo

```
<expr> → <expr> <op> <expr>
       | A | B | C

<op> → * | +
```

- A primeira expressão completamente conhecida é "C * A";
- O compilador gera código para T1 = C * A, substituindo <expr> por T1;

Código Gerado:

```
T1 = C * A;
```

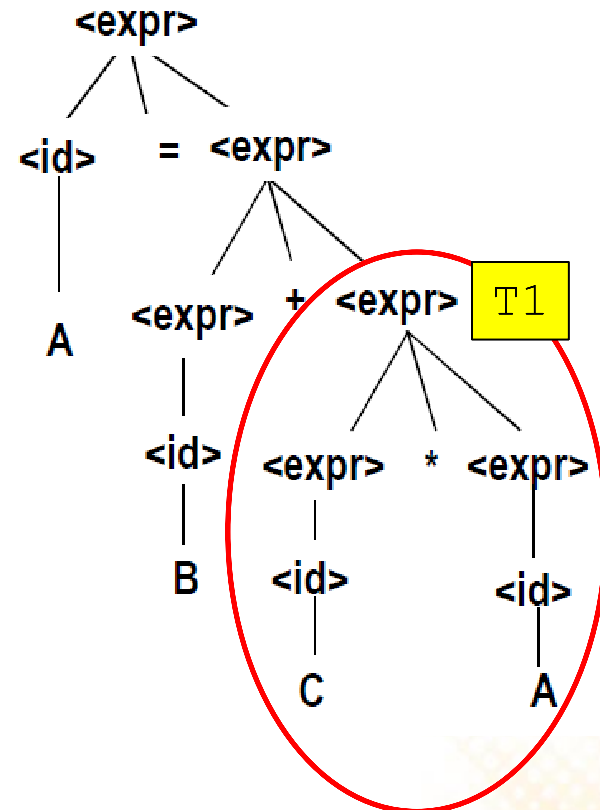

Parse Trees – Exemplo

```
<expr> → <expr> <op> <expr>
       | A | B | C

<op> → * | +
```

- A expressão seguinte completamente conhecida é "B + <expr>" onde <expr> é igual a T1.

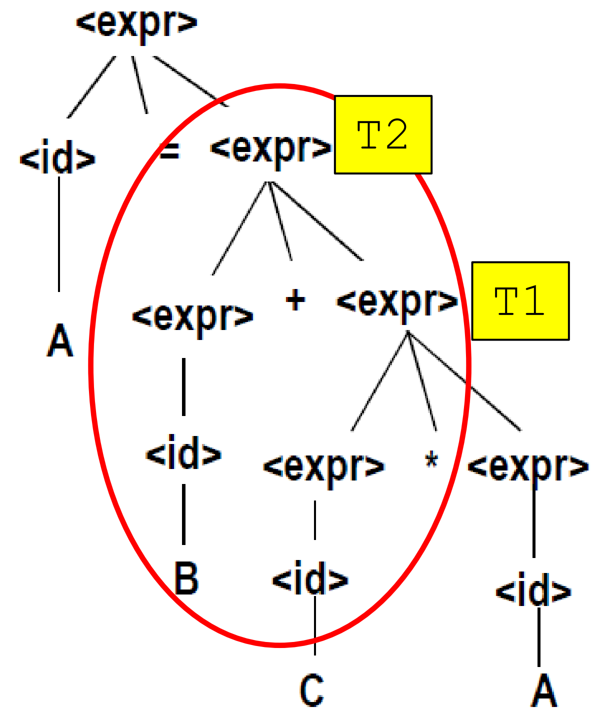

Código Gerado:

```
T1 = C * A;
T2 = B + T1;
```

Parse Trees – Exemplo

```
<expr> → <expr> <op> <expr>
       | A | B | C

<op> → * | +
```

- A última expressão completamente conhecida é "A = <expr>" onde <expr> é T2.

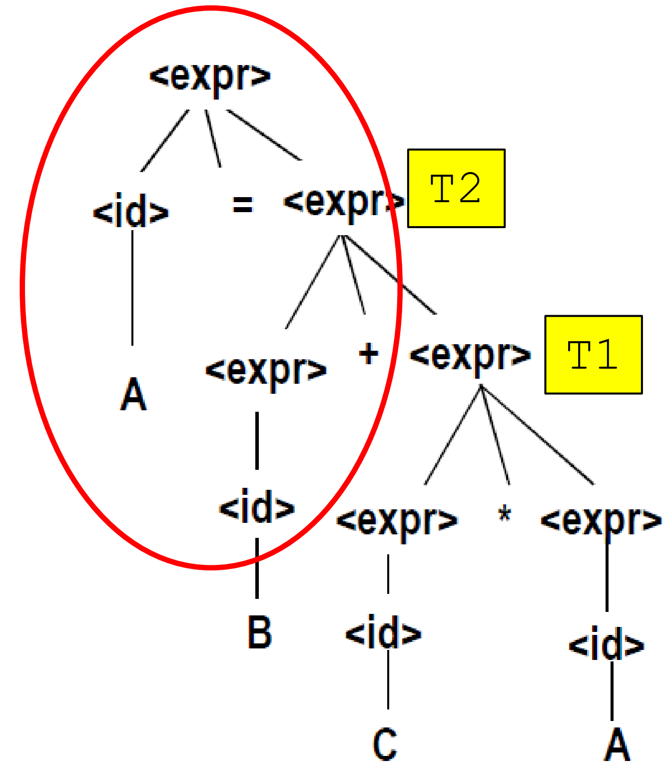

Código Gerado:

```
T1 = C * A;
T2 = B + T1;
A = T2;
```

Árvore de Sintaxe

- Após a análise, os **detalhes de derivação** não são necessários para fases subsequentes do processo de compilação.

- O Analisador Semântico remove as produções intermediárias para criar uma **árvore sintática abstrata** (*abstract syntax tree*).

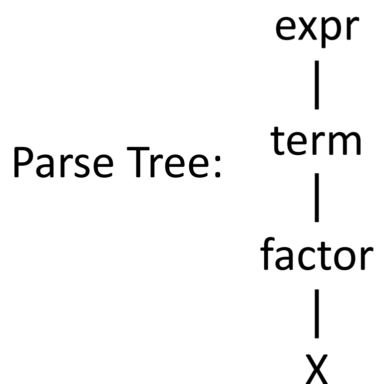

Regras Gramaticais

- É possível derivar significado (**semântica**) da árvore de análise:
  - Operadores são **avaliados** quando uma sentença é reconhecida;
  - As partes mais baixas da parse tree são completadas primeiro;
  - Assim um operador gerado mais baixo em uma parse tree é avaliado primeiro;
  - Em outras palavras, um operado gerado mais baixo na parse tree tem **precedência** sobre um operador produzido acima deste.

Exercício 01

- Considere a seguinte gramática em notação BNF:

```
<assign> → <id> = <expr>
<id> → A | B | C
<expr> → <id> + <expr>
       | <id> * <expr>
       | ( <expr> )
       | <id>
```

- Apresente uma derivação à extrema esquerda e construa a árvore de análise para cada uma das seguintes sentenças:
  a) A = A * (B + (C * A))
  b) B = C * (A * C + B)
  c) A = A * (B + (C))

Precedência de Operadores

- A ordem de produção afeta a ordem de computação.

- Considerando a seguinte gramatica:

```
<assignment> → <id> = <expression> ;
<expression> → <id> + <expression>
              | <id> - <expression>
              | <id> * <expression>
              | <id> / <expression>
              | <id>
              | <number>
<id> → A | B | C | D
<number> → 0|1|2|3|4|5|6|7|8|9
```

- Qual o resultado da expressão: A = B + C * D?

Precedência de Operadores

- A = B + C * D

```
<assignment> → <id> = <expression>
<expression> → <id> + <expression>
             | <id> - <expression>
             | <id> * <expression>
             | <id> / <expression>
             | <id>
             | <number>
<id> → A | B | C | D
<number> → 0|1|2|3|4|5|6|7|8|9
```

```
<assignment> => <id> = <expression>
             => A = <expression>
             => A = <id> + <expression>
             => A = B + <id> * <expression>
             => A = B + C * <expression>
             => A = B + C * <id>
             => A = B + C * D
```

`A = B + (C * D)`

Recursão à direita produz parse trees associativas á direita.

Precedência de Operadores

- A = B + C * D

```
<assignment> → <id> = <expression>
<expression> → <expression> + <id>
              | <expression> - <id>
              | <expression> * <id>
              | <expression> / <id>
              | <id>
              | <number>
<id> → A | B | C | D
<number> → 0|1|2|3|4|5|6|7|8|9
```

```
A = (B + C) * D
```

```
<assignment> => <id> = <expression>
             => A = <expression>
             => A = <expression> * <id>
             => A = <expression> + <id> * <id>
             => A = <id> + <id> * <id>
             => A = B + <id> * <id>
             => A = B + C * <id>
             => A = B + C * D
```

Recursão à esquerda produz parse trees associativas á esquerda.

Gramaticas Ambíguas

- Algumas gramáticas podem gerar parse trees diferentes.

```
<assign> → <id> = <expr>
<id> → A | B | C
<expr> → <expr> + <expr>
       | <expr> * <expr>
       | ( <expr> )
       | <id>
```

A = B + C * A

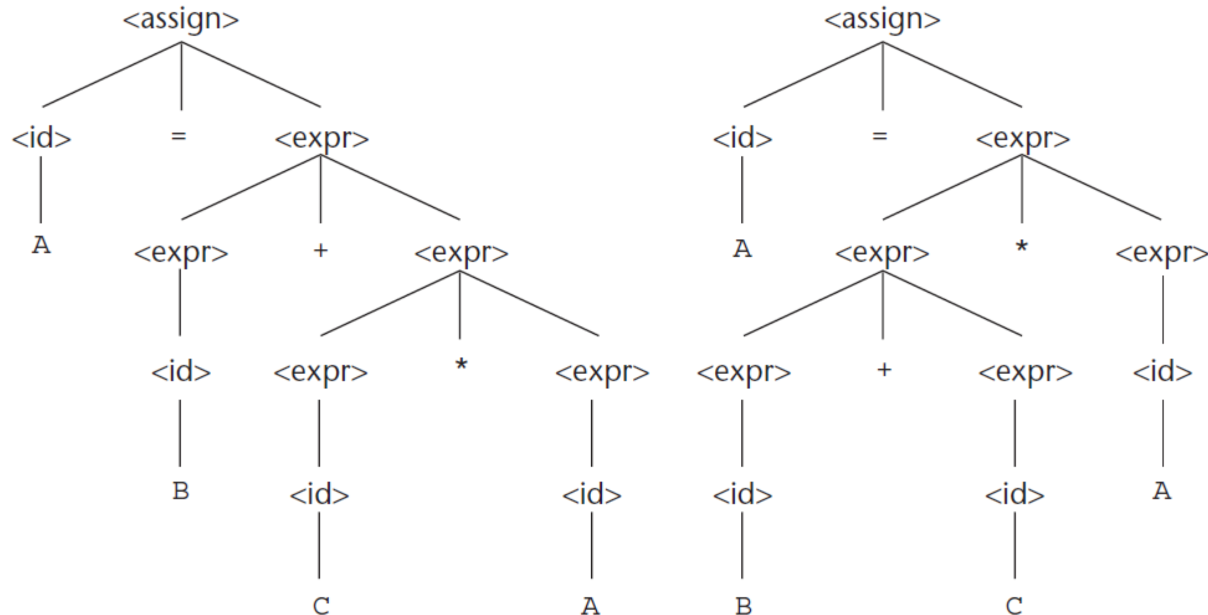

Gramaticas Ambíguas

- Uma gramática é ambígua se ela gera formas sentenciais que possuem duas ou mais parse trees distintas.

- A ambiguidade ocorre porque a gramática especifica muito pouco da estrutura sintática, permitindo que que a parse tree cresça tanto para a direita como para esquerda.

- **Porque isso importa?**
  - Compiladores geralmente baseiam a **semântica** das sentenças na sua forma **sintática**.
    - O compilador decide qual código de máquina gerar examinando a parse tree;
    - Se uma sentença tem mais de uma parse tree, o significado da sentença não é único!

Gramaticas Ambíguas

- Soluções para gramáticas ambíguas:
  - Reescrever a gramática;
  - O algoritmo de análise pode utilizar informações não gramaticais fornecidas pelo projetista para criar a árvore correta:
    - Projetista provê uma tabela de precedência e associatividade dos operadores;
    - Projetista pode impor regras de como a gramática deve ser usada. "Sempre escolha a primeira regra quando mais de uma poder ser utilizada em uma derivação".

Gramaticas Ambíguas

- Soluções para gramáticas ambíguas – Exemplo:

```
<assign> → <id> = <expr>
<id> → A | B | C
<expr> → <expr> + <expr>
        | <expr> * <expr>
        | ( <expr> )
        | <id>
```

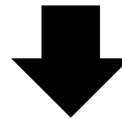

```
<assign> → <id> = <expr>
<id> → A | B | C
<expr> → <expr> + <term>
        | <term>
<term> → <term> * <factor>
        | <factor>
<factor> → ( <expr> )
          | <id>
```

Grafos de Sintaxe

- As regras de uma BNF podem ser representadas através de **grafos de sintaxe** (diagrama de sintaxe):
  - Grafo direcionado;
  - Um grafo é gerada para cada regra;
  - Símbolos não-terminais são representados através de vértices retangulares;
  - Símbolos terminais são representados através de símbolos elípticos.

Grafos de Sintaxe

```
<expression> → <term> | <term> + <expression>
<term> → <factor> | <term> * <factor>
<factor> → <constant> | <variable> | ( <expression> )
<variable> →x | y | z
<constant> → <digit> | <digit> <constant>
<digit> → 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9
```

expression:

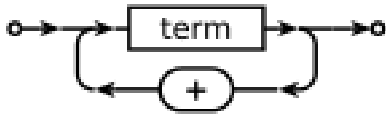

term:

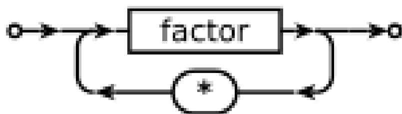

constant:

factor:

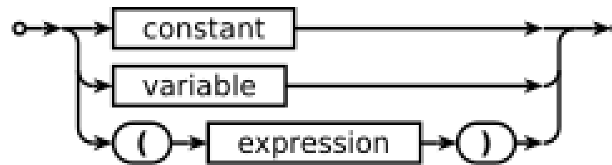

variable:

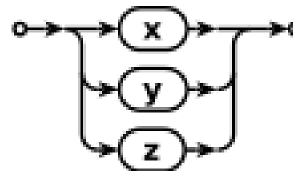

digit:

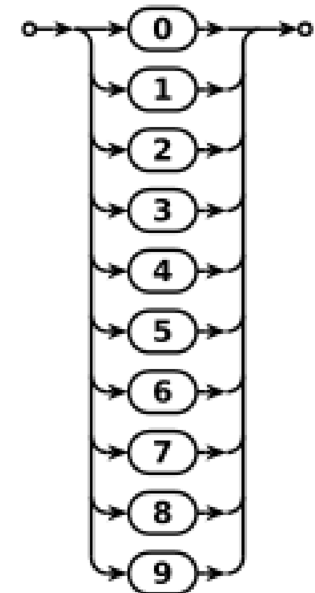

Limitações da BNF

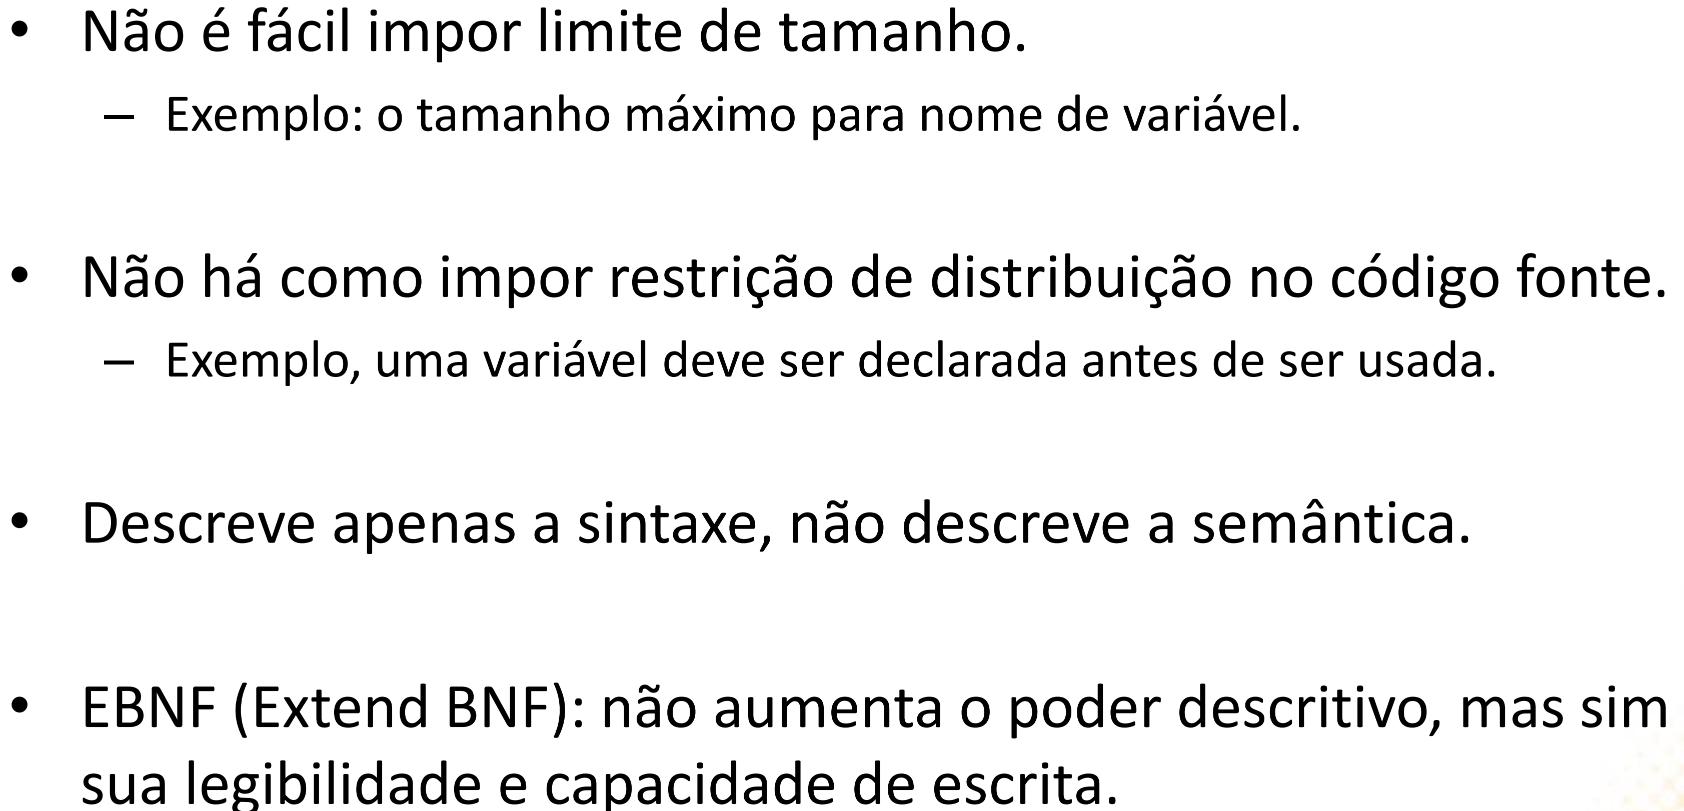

Gramáticas e Reconhecedores

- Há uma estreita ligação entre dispositivos de **geração** e de **reconhecimento**.

- Logo, dada uma gramática livre do contexto de uma dada linguagem seu reconhecedor pode ser **algoritmicamente gerado**.

- Dentre os mais conhecidos geradores de analisadores sintáticos estão:
  - yacc (yet another compiler-compiler);
  - antlr (another tool for language rocognition).

Exercícios

1) Prove que a seguinte gramática é ambígua:

```
<S> → <A>
<A> → <A> + <A> | <ID>
<ID> → a | b | c
```

Exercícios

2) Reescreva a gramática abaixo corrigindo a sua ambiguidade:

```
<stmt> → <if_stmt>
<if_stmt> → if <logic_expr> then <stmt>
          | if <logic_expr> then <stmt> else <stmt>
```

Exemplo:

```
if <logic_expr> then if <logic_expr> then <stmt> else <stmt>
```

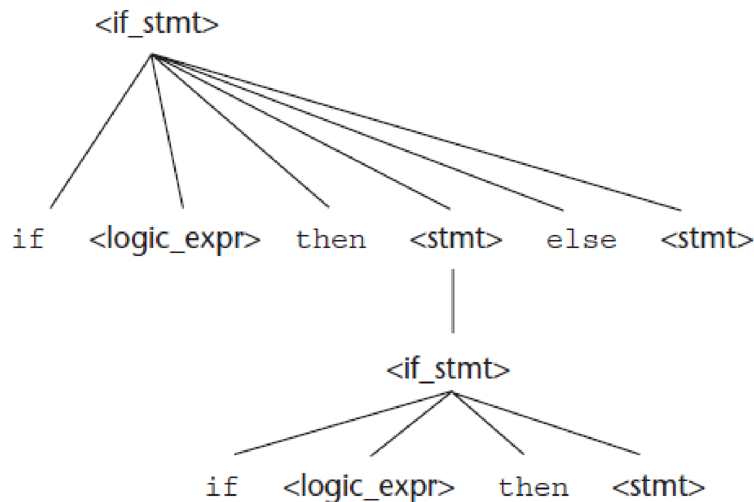

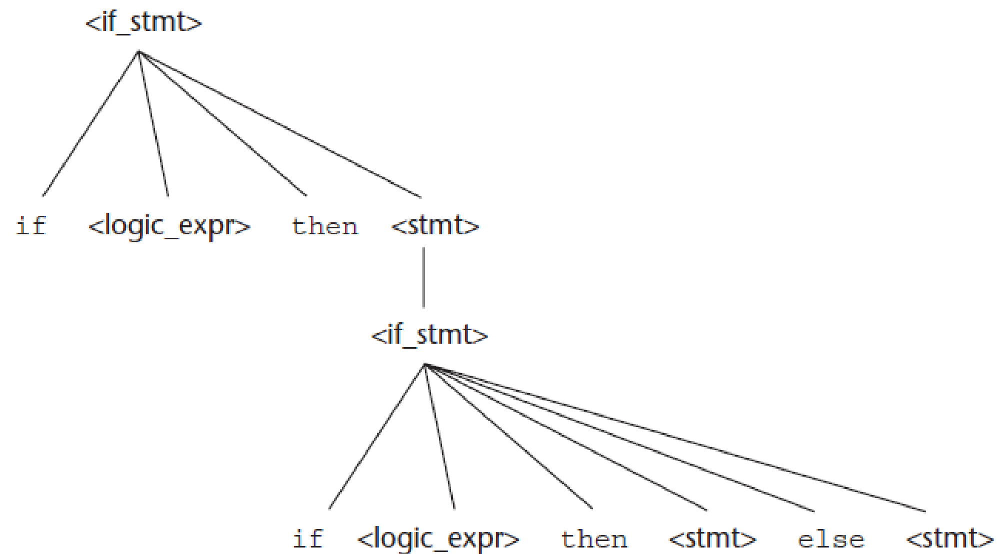

Leitura Complementar

- Sebesta, Robert W. **Conceitos de Linguagens de Programação**. Editora Bookman, 2011.

- **Capítulo 3: Descrevendo a Sintaxe e a Semântica**