CTC-41

Compiladores

Carlos Alberto Alonso Sanches

CTC-41

6) Análise semântica

Erros de contexto, linguagem C-

Análise semântica

- As sintaxes das linguagens de programação geralmente são definidas através de uma **gramática livre de contexto**, cujos *parsers* possuem uma eficiência bastante satisfatória.
- No entanto, nas linguagens de programação é preciso realizar algumas verificações que não podem ser descritas por uma gramática livre de contexto:
  - **Declarações e escopo**: declarar antes de usar, identificadores válidos e únicos, escopo correto, índices válidos para vetores, campos de registros, rótulos não repetidos, etc.
  - **Compatibilidade de tipos**: entre operadores e operandos, nos dois lados de uma atribuição, entre argumentos de chamada e parâmetros declarados, valor retornado de uma função, protótipo e definição de subprograma, etc.
  - **Fluxo de controle**: uso de *break* e *continue*, detecção de recursão infinita, etc.
- Para evitar o uso de uma gramática sensível ao contexto, estes aspectos semânticos são verificados com métodos específicos.
- A análise semântica tem caráter estático, isto é, não verifica possíveis erros que ocorrem em tempo de execução (exemplo: acesso inválido devido a valor de variável lida).

Exemplo: declaração na linguagem C

- A linguagem C permite que o nome de uma função seja usado também como nome de variável local dessa mesma função. No entanto, uma função não pode ter o mesmo nome de uma variável global.
- Exemplo:

```
1 #include <stdio.h>
2 int a = 7;
3 int b ( ) { int b = 3; return a+b; }
4 float x ( ) { float a = 8.7; return a; }
5 void main ( ) {
6    char a = '$'; int c; float d;
7    c = b( ); d = x( );
8    printf ("a = %c, c = %d, d = %g", a, c, d);
9 }
```

Linha 2: declaração legal de **a**

Linha 3: declarações legais de **b**

Linha 4: declaração legal de **a**

Linha 6: declaração legal de **a**

Se a função da linha 3 tivesse nome **a**, seria uma declaração ilegal

Exemplo: escopo na linguagem C

- Em linguagens organizadas por blocos como C (ou também naquelas que admitem aninhamento de subprogramas), será preciso incluir informação sobre o escopo na Tabela de Símbolos.
- Exemplo:

```
void main  ( ) {
     ...

     { // Início do Bloco 1
          int  a;
          ...
          { // Início do Bloco 2
                    ...
                    { // Início do Bloco 3
                              ... =  ... + a + ... ;
                    } // Fim do Bloco 3
          } // Fim do Bloco 2

     }  // Fim do Bloco 1

     {  // Início do Bloco 4
          ... = ... + a + ... ;
     }  // Fim do Bloco 4

}
```

Variável **a** é declarada no Bloco 1

Uso correto de **a** dentro do Bloco 3

Uso incorreto de **a** dentro do Bloco 4

Tabela de símbolos

- A Tabela de Símbolos é uma estrutura de dados auxiliar, cujo conteúdo é criado ou alterado nas três fases de análise.
- Os dados armazenados nesta tabela dependem das ações semânticas implementadas. De modo geral, seus símbolos contêm as seguintes informações, entre outras:
  - Identificador associado
  - O que representa: variável ou função
    - Se for função: sua lista de parâmetros
  - Escopo ou nível da sua declaração (pode haver ponteiro para quem o define)
  - Seu tipo: *int*, *float*, *void*, etc.
  - Linhas do código fonte onde aparece
  - Endereço atribuído na geração de código
- Costuma ser implementada com *hashing*, que permite acesso em tempo quase constante:
  - Subprograma: *hashing* utiliza somente nome do subprograma
  - Variável: *hashing* utiliza nome da variável e nome do escopo onde está declarada

Algumas operações comuns

- Podemos enumerar algumas operações comuns utilizadas no manuseio da Tabela de Símbolos:
  - **Busca**: busca um identificador em um determinado escopo. Pode retornar uma *flag* que indica se o nome já estava presente; em caso negativo, retorna um ponteiro para a posição correspondente.
  - **Insere**: insere um identificador em um determinado escopo. Pode retornar uma *flag* que indica se o nome já estava presente; em caso negativo, retorna um ponteiro para a posição correspondente.
  - **Elimina**: remove todos os símbolos que estão em um determinado escopo.
  - **Declarado**: verifica se um identificador está declarado em um determinado escopo.
  - **DefineAtributos**: define os valores dos atributos em uma posição da Tabela de Símbolos.
  - **ObtemAtributos**: obtém os atributos de uma posição da Tabela de Símbolos.
  - etc.

Durante a análise léxica

- A Tabela de Símbolos pode ser consultada ou atualizada durante a análise léxica.
- Por exemplo, considere a situação em que um identificador ID é encontrado:
  - Verificar o próximo *token* :
    - Se for "(", então ID é nome de uma função;
    - Caso contrário, ID é nome de uma variável.
  - Se o *token* anterior for "int", "float" ou "void": inserir ID na Tabela de Símbolos.
  - Caso contrário, atualizar na Tabela de Símbolos as linhas em que ID aparece.

Durante a análise sintática

- Durante a construção da árvore sintática, podem ser feitas consultas e atualizações na Tabela de Símbolos, com o objetivo de realizar verificações semânticas.
- Exemplo de análise semântica na produção gramatical $E_1 \rightarrow E_2$ / ID:
  - Se Busca(ID) == false:
    - Então: Erro("variável não declarada")
    - Senão: Se (E_2.tipo ≠ inteiro ou ID.tipo ≠ inteiro):
      - Então: Erro ("tipo inválido para a operação")
  - Se não ocorreu erro:
    - Então: E_1.tipo = inteiro; E_1.val = E_2.val / ID.val

Estrutura de blocos

- Blocos são comandos compostos com declarações no início.
- A linguagem C permite blocos, mas não possui aninhamento de subprogramas.
- Os escopos definidos pelos blocos formam uma árvore hierárquica:
  - O escopo global é a raiz dessa árvore.
  - Os subprogramas e os blocos internos são filhos do subprograma onde são declarados.
  - Os escopos dos blocos podem ser representados na Tabela de Símbolos através de identificadores artificiais (exemplo: ##bloco01, ##bloco02, etc.).
  - Cada identificador de escopo pode ter uma lista de escopos filhos.
  - Dois identificadores na Tabela de Símbolos podem ter o mesmo nome, desde que pertençam a escopos distintos.
  - Deste modo, uma busca na Tabela de Símbolos deve informar o identificador procurado e o escopo onde a procura será feita.

Exemplo para blocos

```
void main ( ) {
     {bloco1}
     {bloco2}
}

int f1 ( ) {
     {bloco3}
     {bloco4}
}

float f2 ( ) {
     struct st {
          int c1;
          float c2;
}
}
```

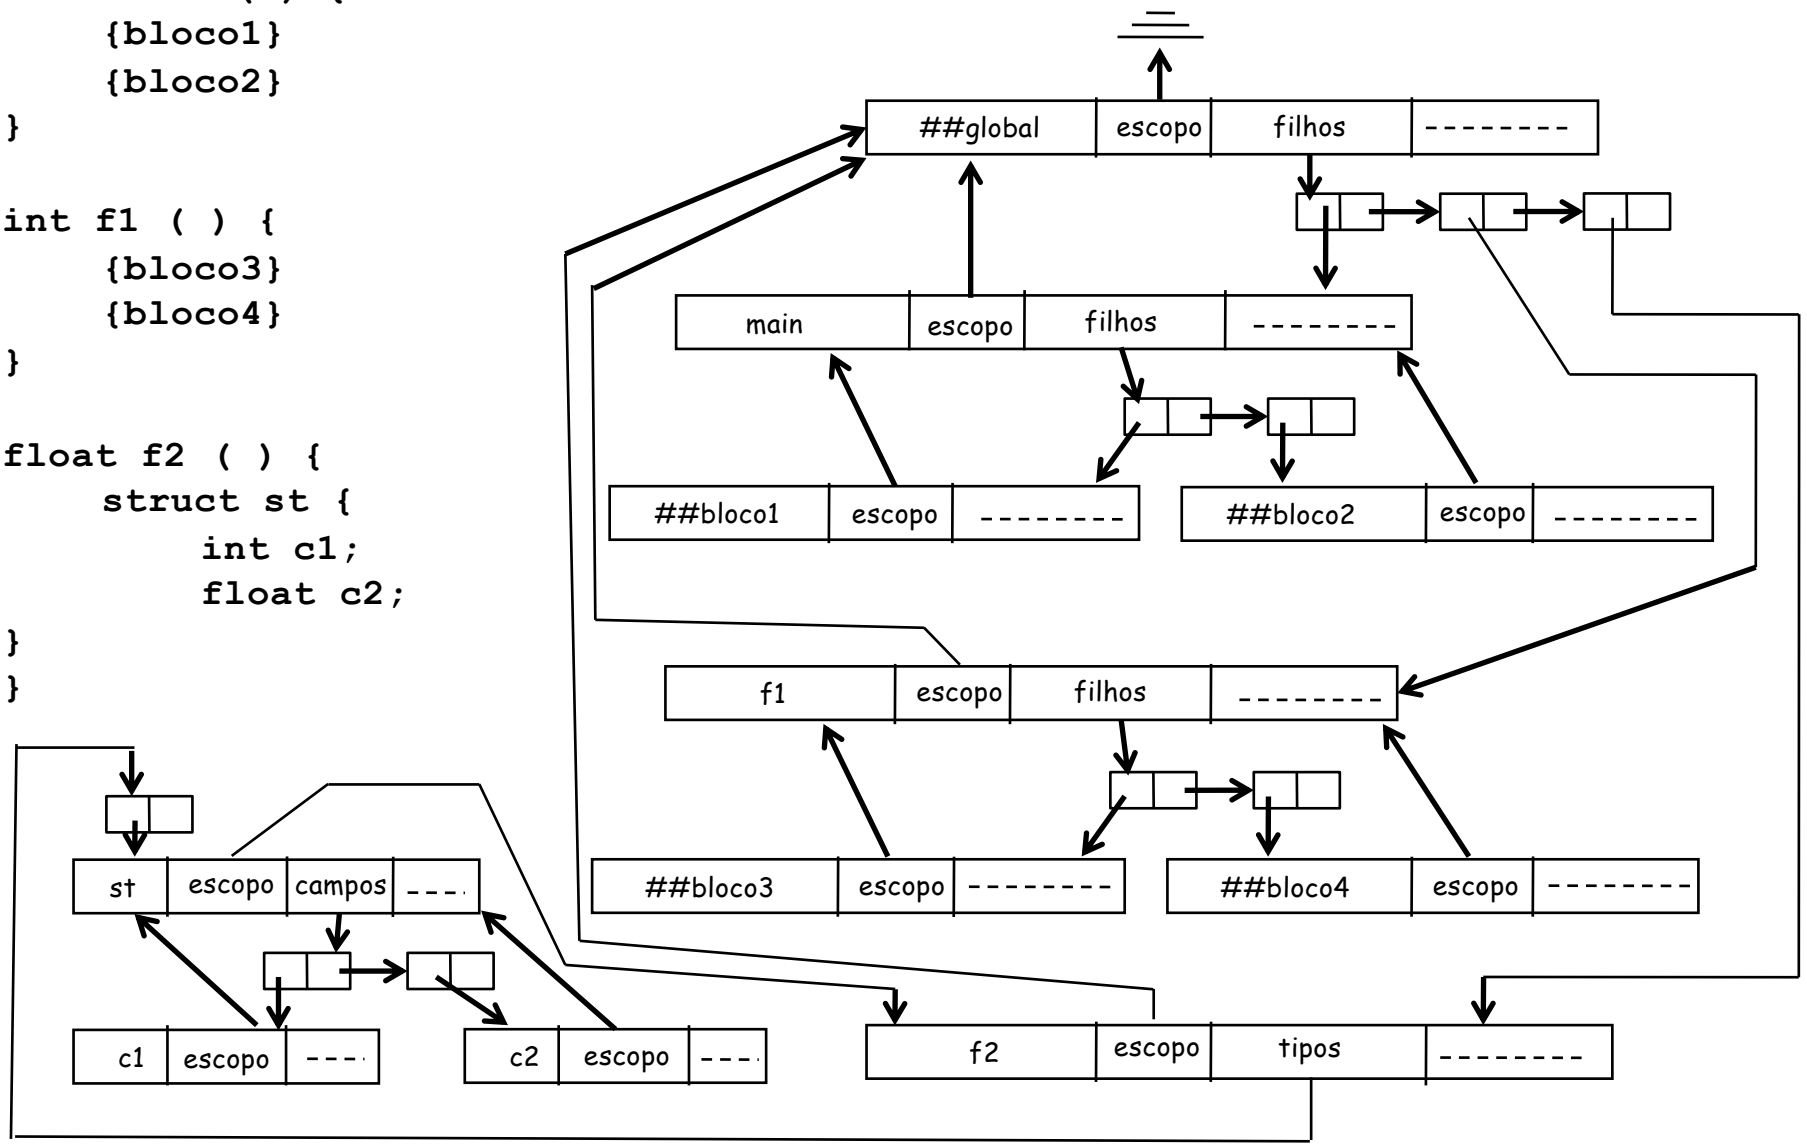

Exemplo para função

```
int f1 (int a, float b, boolean c)
{ ....... }
```

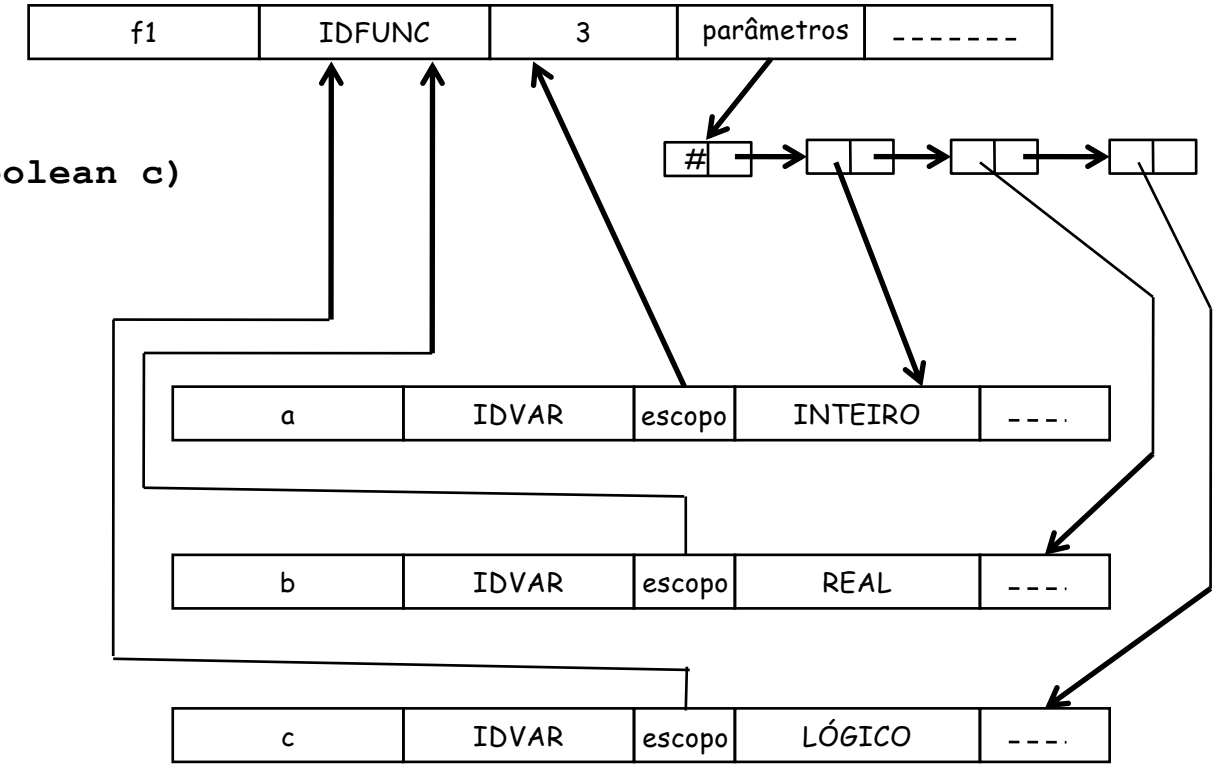

Em cada chamada de **f1**, deverá haver 3 argumentos cujos tipos devem ser respectivamente compatíveis com **a**, **b** e **c**

Exemplo de regras semânticas

- Considere a gramática abaixo:

  decl → tipo ListaVar
  tipo → int | float
  ListaVar → ID, ListaVar | ID

- Regras semânticas que devem ser verificadas durante a análise sintática:

Produção gramatical	Regras semânticas
decl → tipo ListaVar	ListaVar.TipoDado = tipo.TipoDado
tipo → int	tipo.TipoDado = integer
tipo → float	tipo.TipoDado = real
$ListaVar_1$ → ID, $ListaVar_2$	ID.TipoDado = $ListaVar_1$.TipoDado $ListaVar_2$.TipoDado = $ListaVar_1$.TipoDado if !Busca(ID) Inserir (ID, ID.TipoDado) else Erro("Identificador já declarado")
ListaVar → ID	ID.TipoDado = ListaVar.TipoDado if !Busca(ID) Inserir (ID, ID.TipoDado) else Erro("Identificador já declarado")

Exemplo de árvore e de tabela

```
1 int gcd(int u, int v) {
2     if (v==0) return u;
3     else return gcd(v, u-u/v*v);
4 }
5 void main(void) {
6     int x; int y;
7     x = input(); y = input();
8     output(gcd(x,y));
9 }
```

Nome	Escopo	Forma	Tipo	Linhas
u	gcd	var	int	1, 2, 3
main	-	fun	void	5
y	main	var	int	6, 7, 8
gcd	-	fun	int	1, 3, 8
v	gcd	var	int	1, 2, 3
x	main	var	int	6, 7, 8

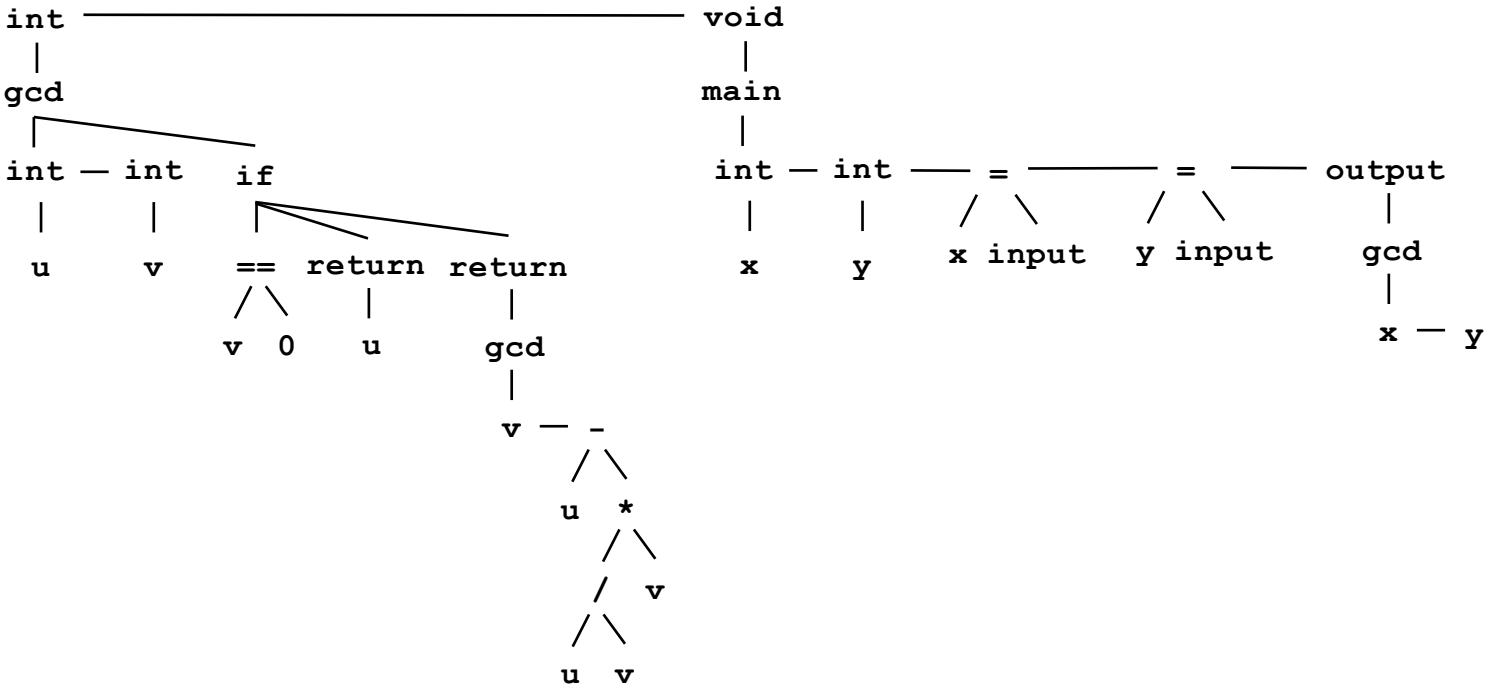

Erros que devem ser detectados

- Na análise semântica a ser implementada neste curso, deverão ser detectados ao menos os seguintes erros:
  - Uso de variável não declarada no escopo corrente (haverá aninhamento de blocos, mas não de funções)
  - Atribuição inválida por disparidade de tipo
  - Declarações inválidas de variáveis e funções:
    - Com tipo inválido (exemplo: variável *void*)
    - Identificador já utilizado (considerar regras de escopo)
  - Chamada de função não declarada
  - Compatibilidade entre argumentos e parâmetros (tipos e quantidade)
  - Ausência da função *main()*

BNF da linguagem C-

programa → declaração-lista
declaração-lista → declaração-lista declaração | declaração
declaração → var-declaração | fun-declaração
var-declaração → tipo-especificador **ID** **;** | tipo-especificador **ID** **[** **NUM** **]** **;**
tipo-especificador → **int** | **void**
fun-declaração → tipo-especificador **ID** **(** params **)** composto-decl
params → param-lista | **void**
param-lista → param-lista **,** param | param
param → tipo-especificador **ID** | tipo-especificador **ID** **[** **]**
composto-decl → **{** local-declarações statement-lista **}**
local-declarações → local-declarações var-declaração | vazio
statement-lista → statement-lista statement | vazio
statement → expressão-decl | composto-decl | seleção-decl | iteração-decl | retorno-decl
expressão-decl → expressão **;** | **;**
seleção-decl → **if** **(** expressão **)** statement | **if** **(** expressão **)** statement **else** statement
iteração-decl → **while** **(** expressão **)** statement
retorno-decl → **return** **;** | **return** expressão **;**
expressão → var **=** expressão | simples-expressão
var → **ID** | **ID** **[** expressão **]**
simples-expressão → soma-expressão relacional soma-expressão | soma-expressão
relacional → **<=** | **<** | **>** | **>=** | **==** | **!=**
soma-expressão → soma-expressão soma termo | termo
soma → **+** | **-**
termo → termo mult fator | fator
mult → ***** | **/**
fator → **(** expressão **)** | var | ativação | **NUM**
ativação → **ID** **(** args **)**
args → arg-lista | vazio
arg-lista → arg-lista **,** expressão | expressão

Características da linguagem C-

- Palavras-chave (sempre minúsculas): **`else if int return void while`**
- Símbolos especiais: **`+ - * / < <= > >= == != = ; , ( ) [ ] { } /* /*`**
- **`ID`** e **`NUM`** são definidos por expressões regulares (há distinção entre maiúsculas e minúsculas):
  - `letra = a | .. | z | A | .. | Z`
  - `ID = letra letra*`
  - `dígito = 0 | .. | 9`
  - `NUM = dígito dígito*`
- Espaço em branco (composto por brancos, mudanças de linha e tabulações) é ignorado, exceto como separador de **`ID`**, **`NUM`** e palavra-chave
- Comentários (delimitados por `/*` e `*/`) não podem ser aninhados, nem colocados dentro de *tokens*
- Todas as variáveis e funções devem ser declaradas antes do uso
- A última declaração deve ser da forma **`void main(void)`**
- Não existem protótipos, ou seja, não há distinção entre declaração e definição
- Os únicos tipos básicos são **`int`** e **`void`**
- **`void`** é exclusivo para funções
- Uma variável é do tipo inteiro ou um vetor de inteiros, indexado a partir do índice 0

Características da linguagem C-

- Os parâmetros de uma função são `void` (sem parâmetros) ou uma lista
- Parâmetros seguidos de colchetes são vetores passadas por referência, e devem casar com uma variável de tipo vetor durante a chamada (ou ativação)
- Não existem parâmetros de tipo função
- Os parâmetros de uma função têm escopo igual ao da declaração dessa função
- Cada chamada (ou ativação) de função tem um conjunto próprio de parâmetros
- Funções podem ser recursivas na medida permitida pela declaração antes do uso
- As declarações locais têm escopo igual ao da lista de declarações da declaração composta e se sobrepõem a qualquer declaração global
- vazio é um não-terminal que identifica cadeia vazia (equivalente a ε)
- A ambiguidade do `else` deve ser resolvida através do aninhamento mais próximo
- Será preciso verificar se os índices dos vetores obedecem aos limites especificados
- Será preciso verificar a quantidade de argumentos e o tipo de cada um deles
- Serão consideradas duas funções pré-definidas no ambiente global:
  - `int input (void) { ... }` : retorna um valor inteiro lido do teclado
  - `void output (int x) { ... }` : imprime seu parâmetro inteiro no monitor e pula linha

Programa em C-: exemplo 1

```
/* SelectionSort em vetor com 10 inteiros */

int x[10];

int minloc (int a[], int low, int high) {
    int i; int x; int k;
    k = low;
    x = a[low];
    i = low + 1;
    while (i < high) {
        if (a[i] < x) {
           x = a[i];
           k = i;
        }
        i = i + 1;
    }
    return k;
}
```

```
void sort (int a[], int low, int high) {
   int i; int k;
   i = low;
   while (i < high-1) {
      int t;
      k = minloc(a,i,high);
      t = a[k];
      a[k] = a[i];
      a[i] = t;
      i = i + 1;
   }
}


void main(void) {
   int i;
   i = 0;
   while (i < 10) {
      x[i] = input();
      i = i + 1;
   }
   sort(x,0,10);
   i = 0;
   while (i < 10) {
      output(x[i]);
      i = i + 1;
   }
}
```

Programa em C-: exemplo 2

```
/* Variáveis em blocos aninhados */


void teste (int b, int a) {
   output(a);
   output(b);
   { int a;
     a = 3;
     int b;
     b = 4;
     output(a);
     output(b);
   }
   a = 5;
   output(a);
}


void main(void) {
   int a;
   a = 1;
   int b;
   b = 2;
   teste(a,b);
   output(a);
   output(b);
}
```

Programa em C-: exemplo 3

```
/* Impressão recursiva da representação
binária do módulo de um inteiro */


void binario (int x) {
    if (x < 2) output(x);
    else {
           binario(x/2);
           output(x - 2*(x/2));
    }
}



void main(void) {
   int x;
   x = input();
   if (x >= 0) binario(x);
   else binario(-x);
}
```