

As fases de um compilador

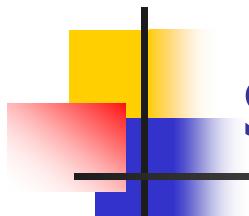


Compilando um programa simples

estrutura de um compilador

formas de organização de um compilador

processo de execução de uma linguagem de alto-nível



Compilando um programa simples

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

O que o compilador vê: o texto é uma sequência de caracteres

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

```
i n t sp g c d ( i n t sp a , sp i
n t sp b ) nl { nl sp sp w h i l e sp
( a sp ! = sp b ) sp { nl sp sp sp sp i
f sp ( a sp > sp b ) sp a sp - = sp b
; nl sp sp sp e l s e sp b sp - = sp
a ; nl sp sp } nl sp sp r e t u r n sp
a ; nl } nl
```

Análise Léxica fornece tokens: uma cadeia de tokens sem espaços e sem comentários

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



ID

Símbolos Simples



Pal.
Reservadas



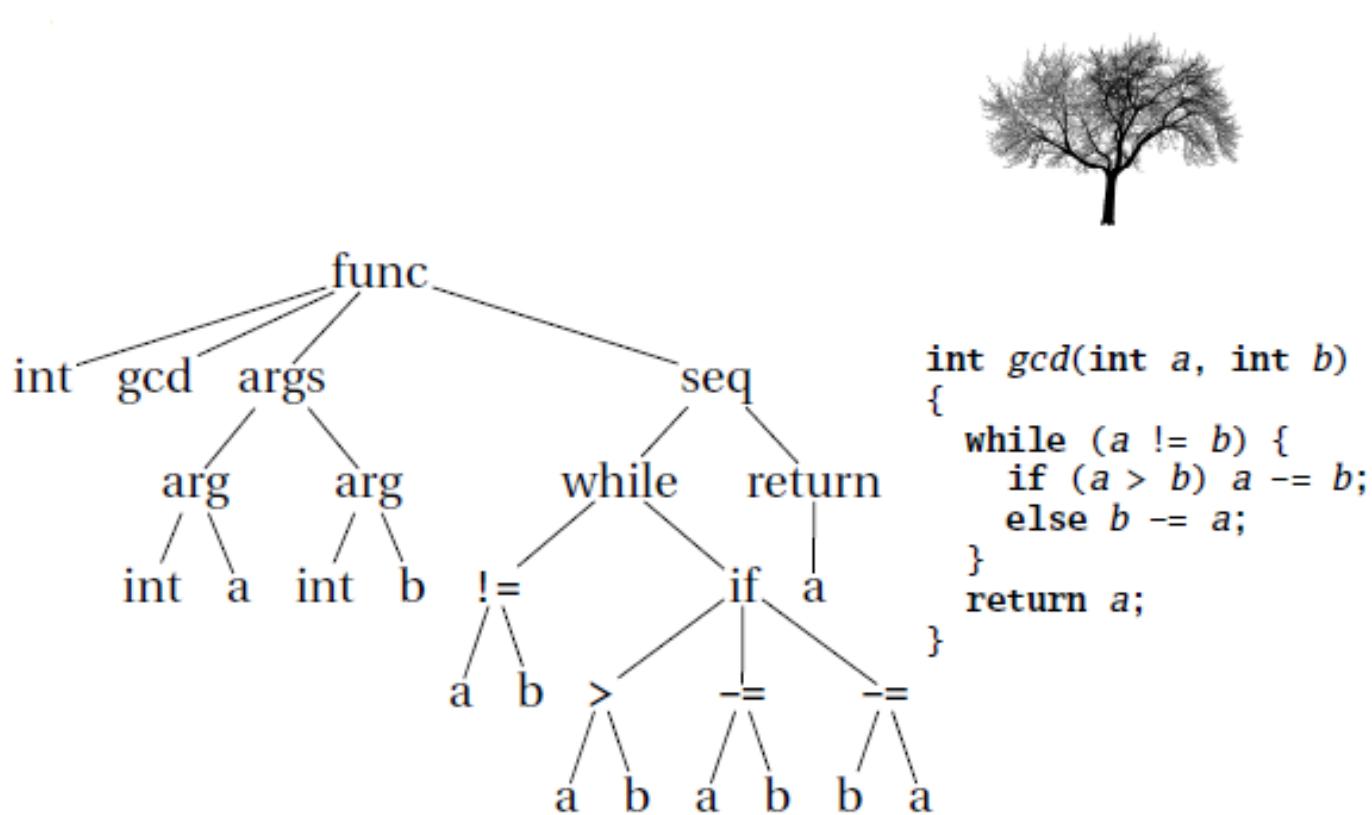
Constantes



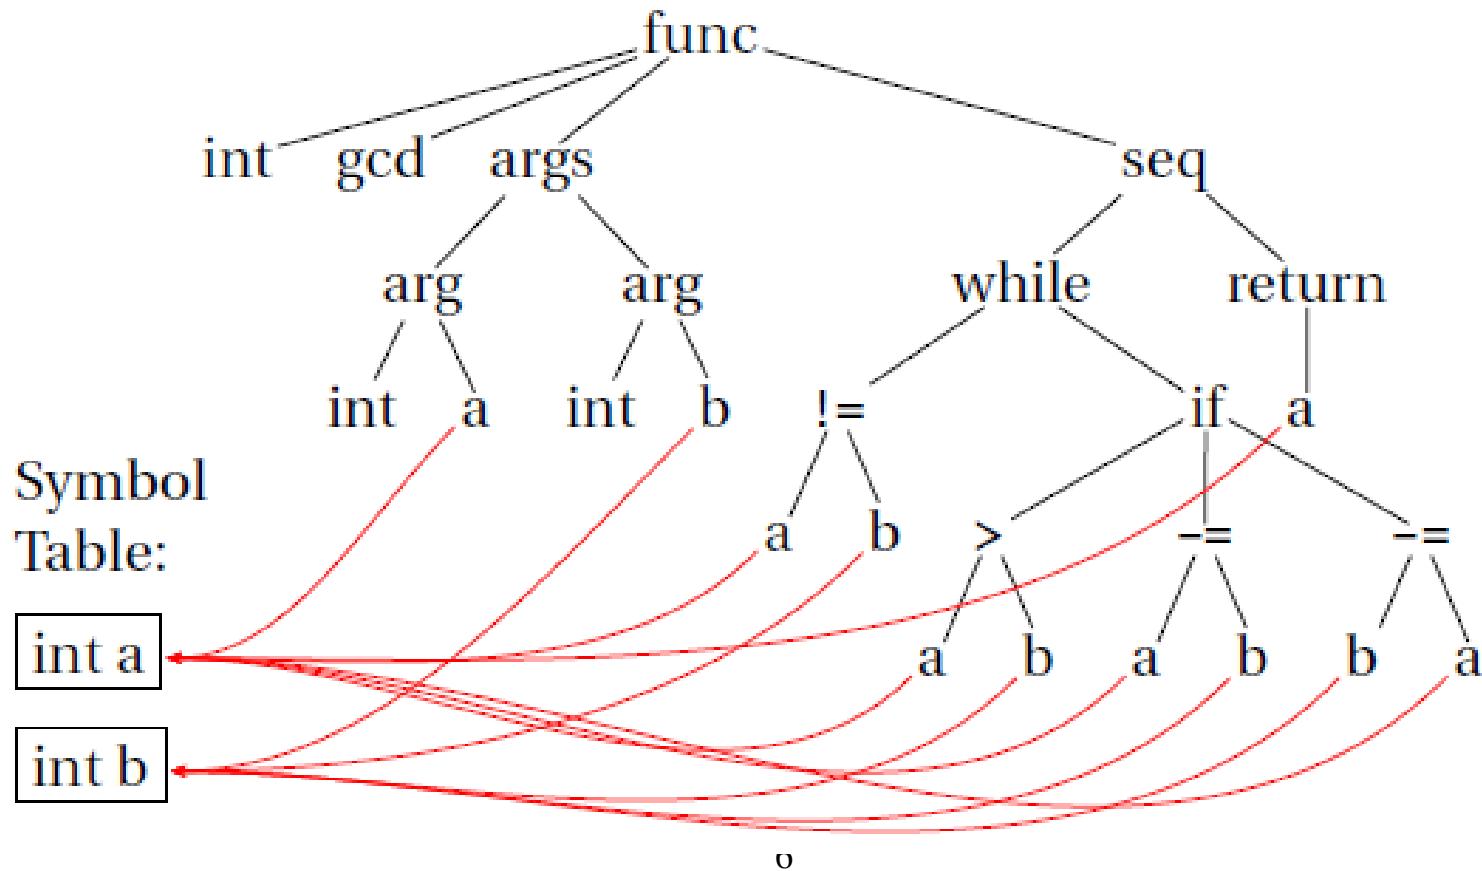
Símbolos
Compostos

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

Análise Sintática fornece uma árvore abstrata construída das regras da gramática



Análise Semântica resolve símbolos, com tipos checados



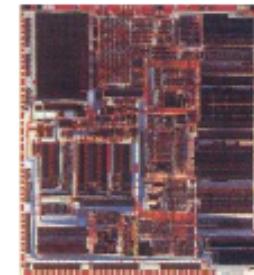
Tradução para uma linguagem intermediária (three-address code: linguagem assembler idealizada com infinitos registradores)

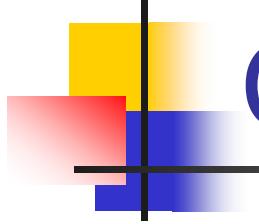
```
L0: sne    $1,  a, b
     seq    $0, $1, 0
     btrue $0, L1      % while (a != b)
     sl     $3,  b, a
     seq    $2, $3, 0
     btrue $2, L4      % if (a < b)
     sub    a,   a, b % a -= b
     jmp    L5
L4: sub    b,   b, a % b -= a
L5: jmp    L0
L1: ret    a
```

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

Geração de código para assembler 80386

```
gcd:  pushl %ebp          % Save FP
      movl  %esp,%ebp
      movl  8(%ebp),%eax  % Load a from stack
      movl  12(%ebp),%edx % Load b from stack
.L8:  cmpl  %edx,%eax
      je    .L3           % while (a != b)
      jle   .L5           % if (a < b)
      subl  %edx,%eax    % a -= b
      jmp   .L8
.L5:  subl  %eax,%edx    % b -= a
      jmp   .L8
.L3:  leave             % Restore SP, BP
      ret
```

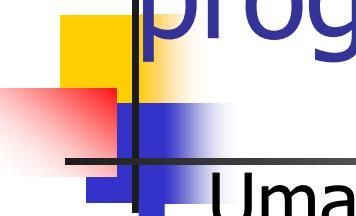




Compilador

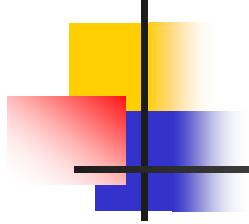
- “Um compilador é um programa que transforma um outro programa escrito em uma **linguagem de programação de alto nível** (LP de alto nível) qualquer em instruções que o computador é capaz de entender e executar.”
- Além de definir **LP de alto nível** com relação à geração de linguagens, podemos definir com base nos 4 paradigmas.

O que é uma linguagens de programação



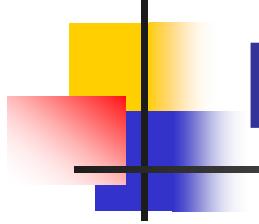
Uma linguagem de programação é uma linguagem destinada a ser usada por uma **pessoa** para expressar um **processo** através do qual um **computador** pode resolver um **problema**

- Dependendo da perspectiva, têm-se
 - Pessoa = paradigma lógico/declarativo
 - Processo = paradigma funcional
 - Computador = paradigma imperativo
 - Problema = paradigma orientado a objetos



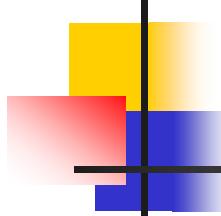
Paradigma lógico/declarativo

- Perspectiva da pessoa
- Um programa lógico é equivalente à descrição do problema expressa de maneira formal, similar à maneira que o ser humano raciocinaria sobre ele
- Exemplo de linguagem: PROLOG



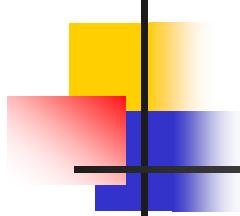
Paradigma funcional

- Perspectiva do processo
- A visão funcional resulta num programa que descreve as operações que devem ser efetuadas (processos) para resolver o problema
- Exemplo de linguagem: LISP



Paradigma imperativo/procedimental

- Perspectiva do computador
- Baseado na execução seqüencial de comandos e na manipulação de estruturas de dados
- Exemplos de linguagens: FORTRAN, COBOL, ALGOL 60, APL, BASIC, PL/I, ALGOL 68, PASCAL, C, MODULA 2, ADA



Paradigma orientado a objetos

- Perspectiva do problema
- Modelagem das entidades envolvidas como objetos que se comunicam e sofrem operações
- Exemplos de linguagens: SIMULA 67, SMALLTALK
 - C++, C# e Java: linguagens híbridas (paradigmas imperativo e orientado a objetos),

Não são Turing-completas, pois não podem simular uma MT, mas são usadas para preparação de documentos

Linguagens de Markup: HTML, SGML, XML

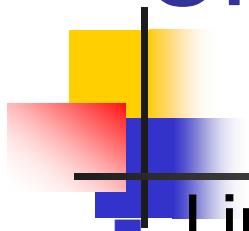
Linguagens de propósito especial:

- YACC para criar parsers
- LEX para criar analisadores léxicos
- MATLAB para computação numérica
- SQL para aplicações com BD

Linguagens de Scripts ou extensão:
AWK, Perl, PHP, Python, Ruby, LUA, JavaScript

O que fazer com o resto das linguagens?

Um pouco de história



Linguagens que introduziram conceitos importantes e que ainda estão em uso

- 1955-1965: FORTRAN, COBOL, ALGOL 60, LISP, APL, BASIC (aplicações simples; preocupação com a eficiência)
- 1965-1971 (com base em ALGOL): PL/I, SIMULA 67, ALGOL 68, PASCAL (pessoas se tornam importantes; preocupação com a inteligibilidade do código, melhores estruturas de controle)
- Anos 70 e 80: MODULA 2, ADA, C++, Java (mudança de processos para dados; Abstração, herança e polimorfismo)

Assembly Language

Before: numbers

55
89E5
8B4508
8B550C
39D0
740D
39D0
7E08
29D0
39D0
75F6
C9
C3
29C2
EBF6

After: Symbols

```
gcd: pushl %ebp
     movl %esp, %ebp
     movl 8(%ebp), %eax
     movl 12(%ebp), %edx
     cmpl %edx, %eax
     je .L9
.L7: cmpl %edx, %eax
     jle .L5
     subl %edx, %eax
.L2: cmpl %edx, %eax
     jne .L7
.L9: leave
     ret
.L5: subl %eax, %edx
     jmp .L2
```

FORTRAN

Before

```
gcd: pushl %ebp
    movl %esp, %ebp
    movl 8(%ebp), %eax
    movl 12(%ebp), %edx
    cmpl %edx, %eax
    je .L9
.L7: cmpl %edx, %eax
    jle .L5
    subl %edx, %eax
.L2: cmpl %edx, %eax
    jne .L7
.L9: leave
    ret
.L5: subl %eax, %edx
    jmp .L2
```

After: Expressions, control-flow

```
10   if (a .EQ. b) goto 20
      if (a .LT. b) then
          a = a - b
      else
          b = b - a
      endif
      goto 10
end
```

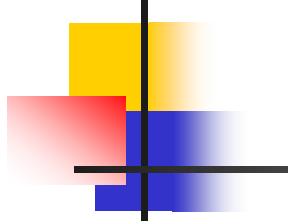
COBOL

Added type declarations, record types, file manipulation

```
data division.  
file section.  
*   describe the input file  
fd  employee-file-in  
      label records standard  
      block contains 5 records  
      record contains 31 characters  
      data record is employee-record-in.  
01  employee-record-in.  
    02  employee-name-in  pic x(20).  
    02  employee-rate-in  pic 9(3)v99.  
    02  employee-hours-in pic 9(3)v99.  
    02  line-feed-in       pic x(1).
```



From cafepress.com



LISP, Scheme, Common LISP

Functional, high-level languages

```
(defun gnome-doc-insert ()
  "Add a documentation header to the current buffer.
Only C/C++ function types are properly handled.
(interactive)
(let (c-insert-here (point))
  (save-excursion
    (beginning-of-defun)
    (let (c-arglist
          c-funcname
          (c-point (point))
          c-comment-point
          c-isvoid
          c-doinsert)
        (search-backward "(")
        (forward-line -2)
        (while (or (looking-at "^$")
                    (looking-at "^ *}")
                    (looking-at "^ \\\"")
                    (looking-at "^#")))
          (forward-line 1)))
```

APL

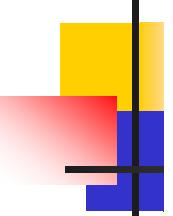
Powerful operators, interactive language, custom character set

```
[0] Z←GAUSSRAND N;B;F;M;P;Q;R
[1] ^ Returns ω random numbers having a Gaussian normal distribution
[2] ^ (with mean 0 and variance 1) Uses the Box-Muller method.
[3] ^ See Numerical Recipes in C, pg. 289.
[4]
[5] Z←l0
[6] M←-1+2★31           ^ largest integer
[7] L1:Q←N-PZ           ^ how many more we need
[8] →(Q≤0)/L2           ^ quit if none
[9] Q←⌈1.3×Q÷2          ^ approx num points needed
[10] P←-1+(2*M-1)×-1+?(Q,2)PM ^ random points in -1 to 1 square
[11] R←+/P×P             ^ distance from origin squared
[12] B←(R≠0)∧R<1
[13] R←B/R ⋄ P←B≠P     ^ points within unit circle
[14] F←(-2×(ΦR)÷R)★.5
[15] Z←Z,,P×F,[1.5]F
[16] →L1
[17] L2:Z←N↑Z
[18] ^ ArchDate: 12/16/1997 16:20:23.170
```

Source: Jim Weigang, <http://www.chilton.com/~jimw/gsrand.html>

At right: Datamedia APL Keyboard





Algol, Pascal, Clu, Modula, Ada

Imperative, block-structured language, formal syntax definition, structured programming

```
PROC insert = (INT e, REF TREE t)VOID:  
    # NB inserts in t as a side effect #  
    IF TREE(t) IS NIL THEN t := HEAP NODE := (e, TREE(NIL), TREE(NIL))  
    ELIF e < e OF t THEN insert(e, l OF t)  
    ELIF e > e OF t THEN insert(e, r OF t)  
    FI;  
  
PROC trav = (INT switch, TREE t, SCANNER continue, alternative)VOID:  
    # traverse the root node and right sub-tree of t only. #  
    IF t IS NIL THEN continue(switch, alternative)  
    ELIF e OF t <= switch THEN  
        print(e OF t);  
        traverse( switch, r OF t, continue, alternative)  
    ELSE # e OF t > switch #  
        PROC defer = (INT sw, SCANNER alt)VOID:  
            trav(sw, t, continue, alt);  
            alternative(e OF t, defer)  
        FI;
```

Algol-68, source <http://www.csse.monash.edu.au/~lloyd/tildeProgLang/Algol68/treemerge.a68>

BASIC

Programming for the masses

```
10 PRINT "GUESS A NUMBER BETWEEN ONE AND TEN"  
20 INPUT A$  
30 IF A$ <> "5" THEN GOTO 60  
40 PRINT "GOOD JOB, YOU GUESSED IT"  
50 GOTO 100  
60 PRINT "YOU ARE WRONG. TRY AGAIN"  
70 GOTO 10  
100 END
```

Started the whole Bill Gates/
Microsoft thing. BASIC was
invented by Dartmouth
researchers John George Kemeny
and Thomas Eugene Kurtz.



Simula, Smalltalk, C++, Java, C#

The object-oriented philosophy

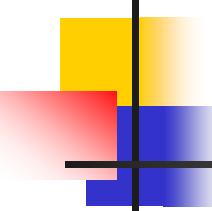
```
class Shape(x, y); integer x; integer y;
virtual: procedure draw;
begin
    comment -- get the x & y coordinates --;
    integer procedure getX;
        getX := x;
    integer procedure getY;
        getY := y;

    comment -- set the x & y coordinates --;
    integer procedure setX(newx); integer newx;
        x := newx;
    integer procedure setY(newy); integer newy;
        y := newy;
end Shape;
```



Efficiency for systems programming

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



ML, Miranda, Haskell

Functional languages with a syntax

```
structure RevStack = struct
  type 'a stack = 'a list
  exception Empty
  val empty = []
  fun isEmpty (s:'a stack):bool =
    (case s
      of [] => true
       | _ => false)
  fun top (s:'a stack): =
    (case s
      of [] => raise Empty
       | x::xs => x)
  fun pop (s:'a stack):'a stack =
    (case s
      of [] => raise Empty
       | x::xs => xs)
  fun push (s:'a stack,x: 'a):'a stack = x::s
  fun rev (s:'a stack):'a stack = rev (s)
end
```

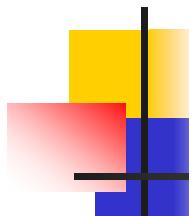
sh, awk, perl, tcl, python, php

Scripting languages: glue for binding the universe together

```
class() {
    classname='echo "$1" | sed -n '1 s/ *.*$/p'
    parent='echo "$1" | sed -n '1 s/^.*: */p'
    hppbody='echo "$1" | sed -n '2,$p''

    forwarddefs="$forwarddefs
    class $classname;"

    if (echo $hppbody | grep -q "$classname()"); then
        defaultconstructor=
    else
        defaultconstructor="$classname() {}"
    fi
}
```

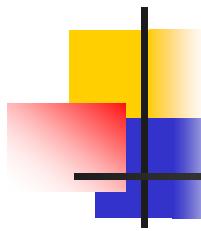


SQL

Database queries

```
CREATE TABLE shirt (
    id SMALLINT UNSIGNED NOT NULL AUTO_INCREMENT,
    style ENUM('t-shirt', 'polo', 'dress') NOT NULL,
    color ENUM('red', 'blue', 'white', 'black') NOT NULL,
    owner SMALLINT UNSIGNED NOT NULL
        REFERENCES person(id),
    PRIMARY KEY (id)
);

INSERT INTO shirt VALUES
(NULL, 'polo', 'blue', LAST_INSERT_ID()),
(NULL, 'dress', 'white', LAST_INSERT_ID()),
(NULL, 't-shirt', 'blue', LAST_INSERT_ID());
```

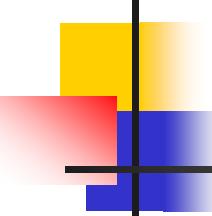


Prolog

Logic Language

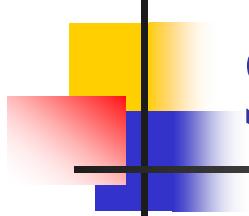
```
edge(a, b).  
edge(b, c).  
edge(c, d).  
edge(d, e).  
edge(b, e).  
edge(d, f).
```

```
path(X, X).  
path(X, Y) :- edge(X, Z), path(Z, Y).
```



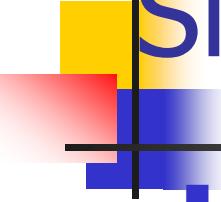
Sintaxe e semântica

- A descrição de uma linguagem de programação envolve dois aspectos principais
 - Sintaxe: conjunto de regras que determinam quais construções são corretas
 - Semântica: descrição de como as construções da linguagem devem ser interpretadas e executadas
- Em Pascal: `a:=b`
 - Sintaxe: comando de atribuição correto
 - Semântica: substituir o valor de `a` pelo valor de `b`



Sintaxe

- As gramáticas de linguagens de programação são utilizadas para produzir ou reconhecer cadeias?



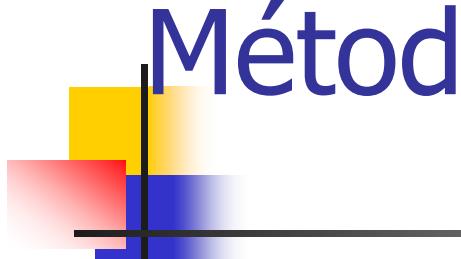
Sintaxe

Descrição de linguagens de programação por meio de gramáticas livres de contexto

- A maioria das linguagens não são livres de contexto, mas sensíveis ao contexto
 - Por exemplo, variável deve ser declarada antes de ser usada
- Métodos para reconhecer gramáticas sensíveis ao contexto são complexos.
- Na prática, especifica-se uma gramática livre de contexto para a linguagem de programação e trata-se a sensibilidade ao contexto de maneira informal
 - Tabela de símbolos

Gramáticas e reconhecedores

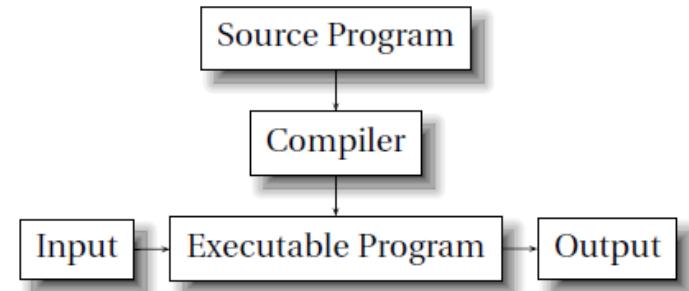
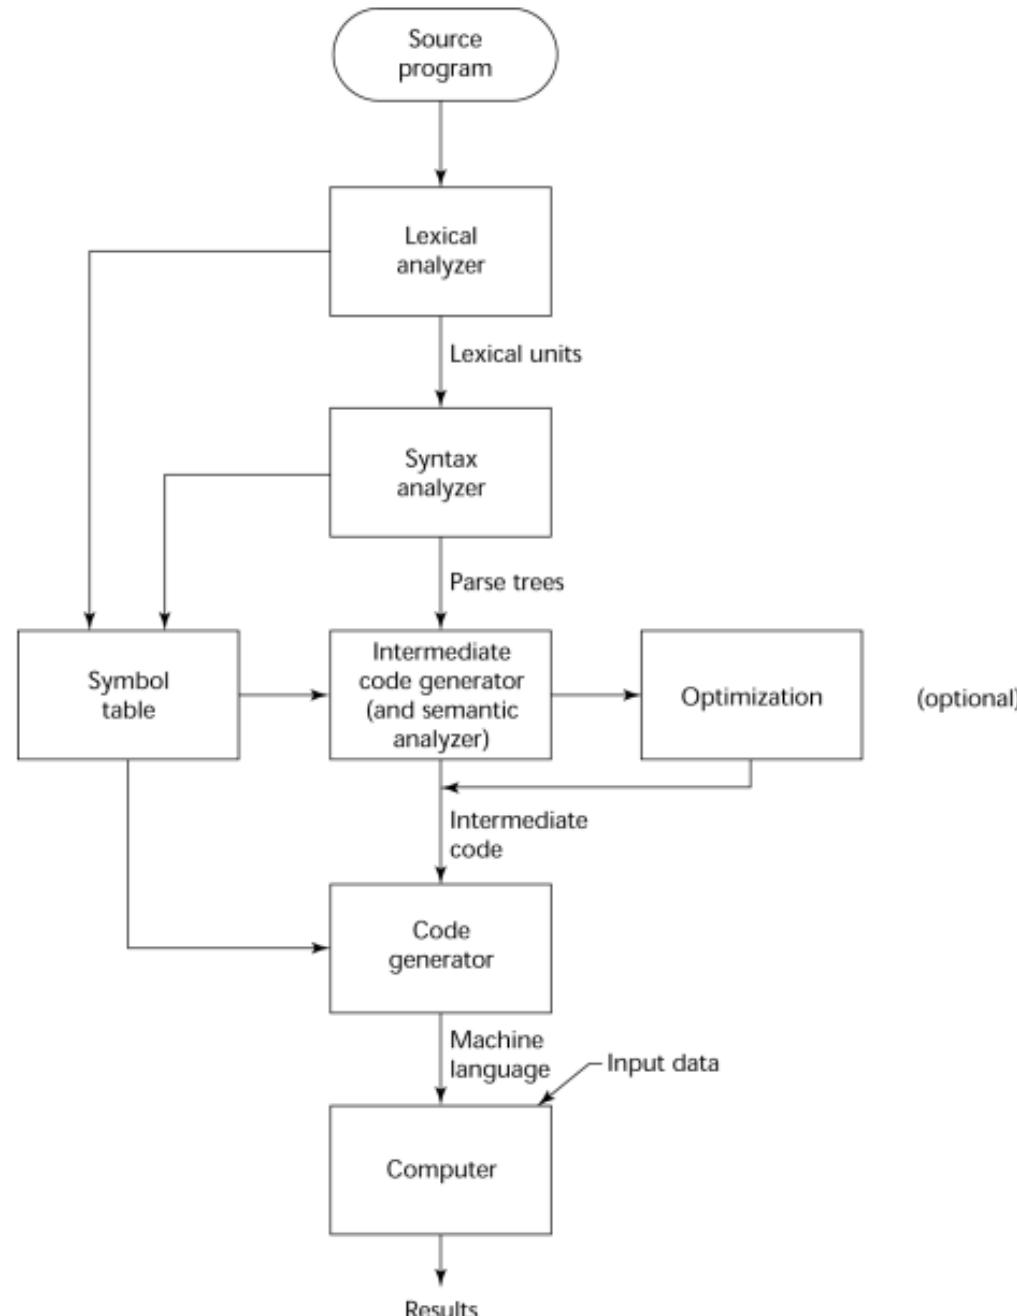
| Gramáticas | Reconhecedores |
|----------------------|--|
| Irrestrita | Máquina de Turing |
| Sensível ao contexto | Máquina de Turing com memória limitada |
| Livre de contexto | Autômato a pilha |
| Regular | Autômato finito |



Métodos de Implementação

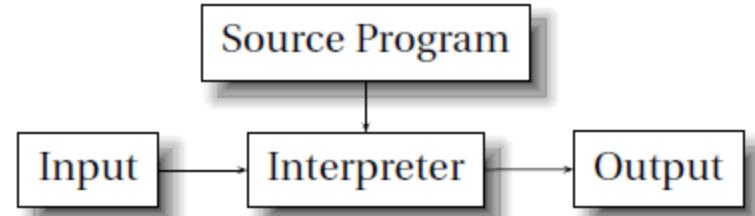
- Compilação
 - Programas são traduzidos em linguagem de máquina
- Interpretação Pura
 - Programas são interpretados por outro programa (interpretador)
- Sistemas Híbridos
 - Oferecem um compromisso entre compiladores e interpretadores puros

Compilador

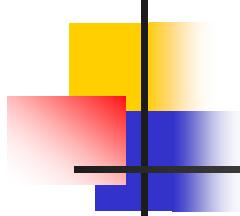


Tradução lenta
Execução rápida

Interpretador



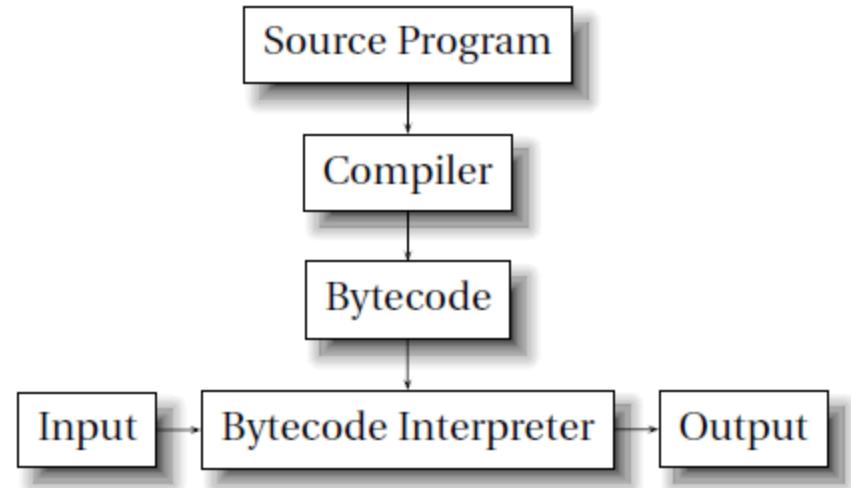
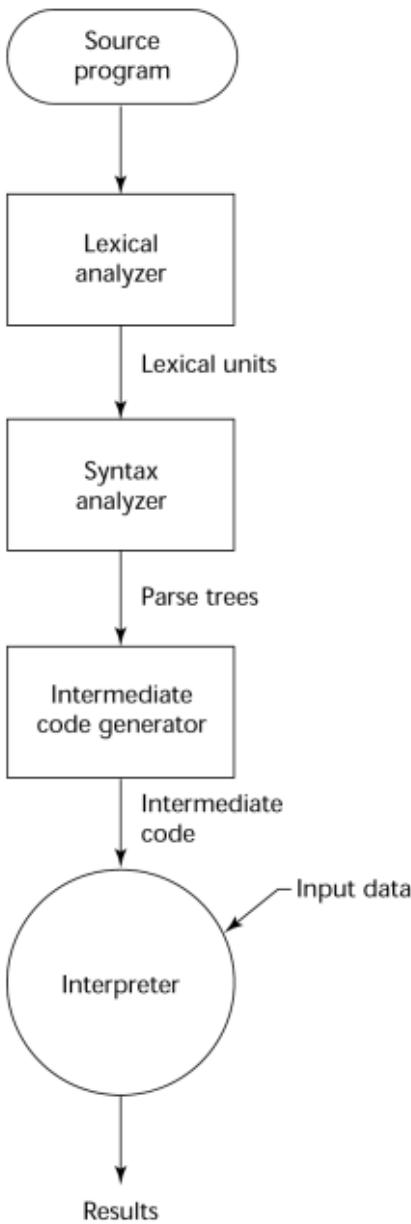
- Não há tradução
- Execução lenta (10 a 100 vezes mais lento que programas compilados)
- Frequentemente requer mais espaço
- Atualmente raro para as linguagens tradicionais, mas está havendo um retorno com as linguagens de script para a Web (por exemplo, JavaScript, PHP)



Sistemas Híbridos

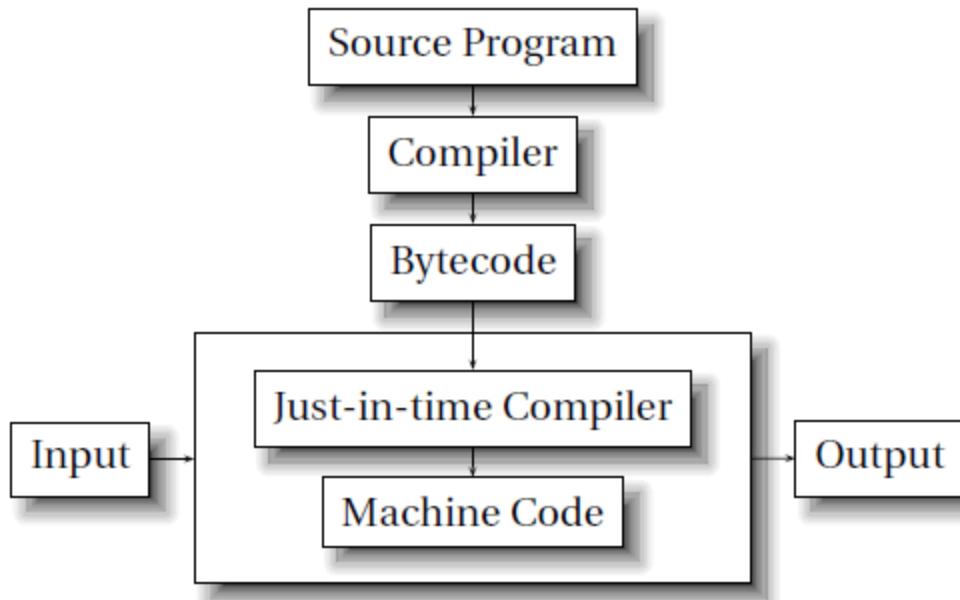
- Há a tradução para uma linguagem intermediária para facilitar a interpretação
- Mais rápido que interpretação pura
- Exemplos:
 - Programas Perl são compilados parcialmente para detectar erros antes da interpretação.
 - Implementações iniciais de Java foram híbridas; o código intermediário, *byte code*, fornece portabilidade para qualquer máquina que tenha um interpretador de byte code e um ambiente de execução (juntos, são chamados de *Java Virtual Machine*)

Interpretador de Bytecodes



O conceito não é novo... Pascal P-code difundiu a linguagem Pascal

Compilador Just in Time



- Traduz inicialmente para uma linguagem intermediária
- Então compila a linguagem intermediária dos subprogramas em código de máquina quando eles são chamados
- Este código é mantido para chamadas subsequentes
- Sistemas JIT são muito usados para Java
- Linguagens .NET são implementadas com um sistema JIT

TIOBE Programming Community Index for February 2010

| Position Feb 2010 | Position Feb 2009 | Delta in Position | Programming Language |
|-------------------|-------------------|-------------------|----------------------|
| 1 | 1 | = | Java |
| 2 | 2 | = | C |
| 3 | 5 | ↑↑ | PHP |
| 4 | 3 | ↓ | C++ |
| 5 | 4 | ↓ | (Visual) Basic |
| 6 | 6 | = | C# |
| 7 | 7 | = | Python |
| 8 | 8 | = | Perl |
| 9 | 9 | = | Delphi |
| 10 | 10 | = | JavaScript |
| 11 | 11 | = | Ruby |
| 12 | 32 | ↑↑↑↑↑↑↑↑↑↑↑↑↑↑↑↑ | Objective-C |
| 13 | - | ↑↑↑↑↑↑↑↑↑↑↑↑↑↑↑↑ | Go |
| 14 | 14 | = | SAS |
| 15 | 13 | ↓↓ | PL/SQL |
| 16 | 17 | ↑ | ABAP |
| 17 | 16 | ↓ | Pascal |
| 18 | 18 | = | ActionScript |
| 19 | 23 | ↑↑↑↑ | Lisp/Scheme |
| 20 | 24 | ↑↑↑↑ | MATLAB |

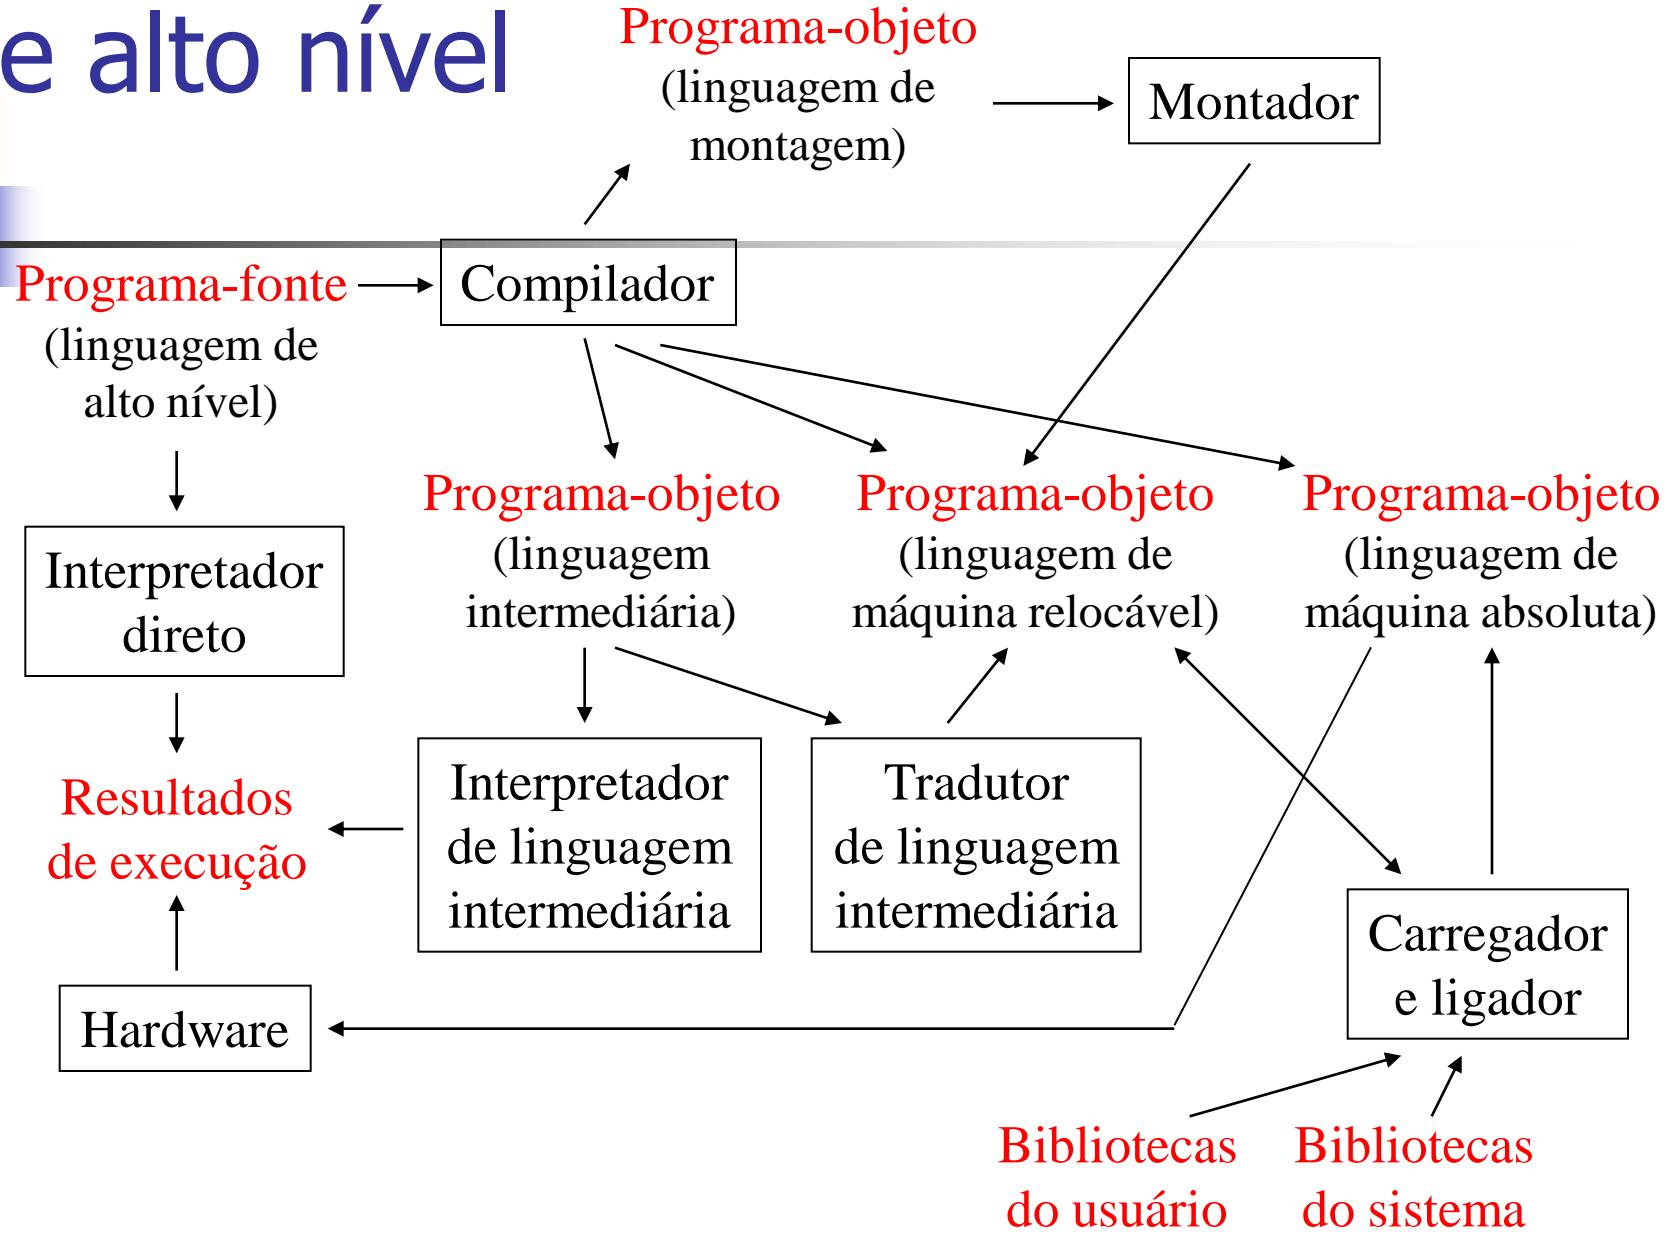
Atualizado mensalmente.
Usa máquinas de busca (Google, MSN, Yahoo!, Wikipedia e YouTube) para calcular o número mundial de usuários, cursos e vendedores de linguagens pagas.

Não se refere à melhor linguagem nem àquela para qual muitas linhas foram escritas.



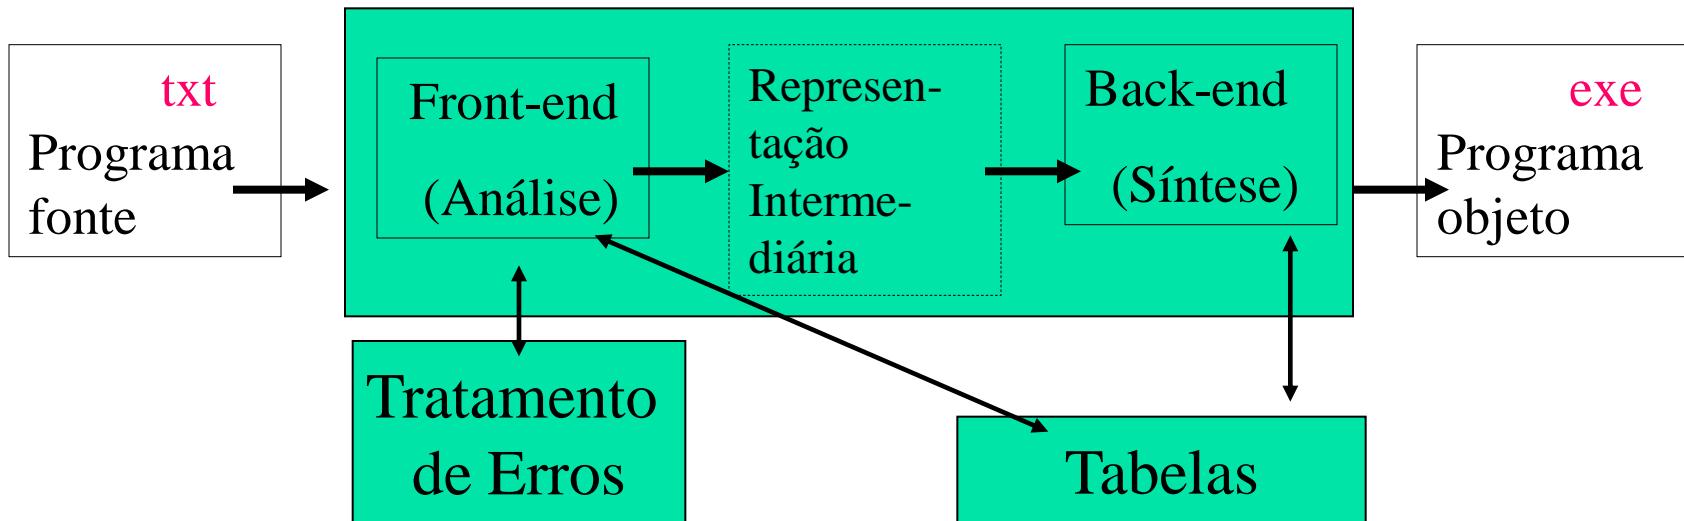
<http://golang.org/>

Execução de linguagens de alto nível



estrutura conceitual de um compilador (1)

Fases da Análise: A Léxica, A Sintática,
A Semântica



Fases da Síntese: Otimização Global,
Geração de Código, Otimização Local

estrutura conceitual de um compilador (2)

Prog. fonte
(cadeia de
caracteres)

Tabela de
símbolos e
atributos

usada em todas as
fases da compilação

Análise
léxica

scanner

Análise
sintática

parser

Tratamento
de erros

tokens

estrutura
sintática

*semantic
routines*

Análise
semântica

representação
Intermediária (RI)

*global
optimization*

Otimizador
global

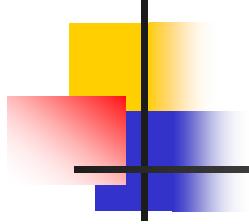
*code
generator*

Gerador de
código

*peephole
optimization*

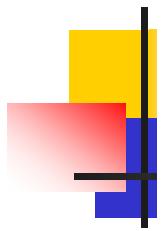
Otimizador
local

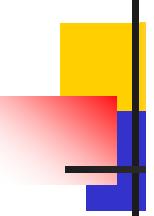
Prog. objeto

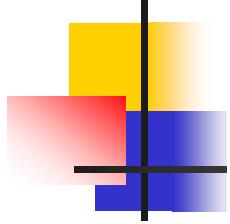


As fases e os erros que elas reportam

- **Análise Léxica:** responsável por ler o arquivo em que está armazenado o programa fonte (da esquerda para a direita) e por reconhecer os *tokens* (ou itens léxicos) e lhes dar um rótulo:
 - Palavras reservadas: `begin, if, var, ... s_begin, s_if, s_var, ...`
 - Identificadores: `X, Y, Z, integer, boolean... id id id id id`
 - Símbolos simples e compostos: `; , := + .. s_; s_, s:= s_+`
 - Constantes:
 - inteiras e reais: `23 23.4 n_int n_real`
 - caracteres e strings: `'a' 'compiladores' caractere cadeia`
 - lógicas: `true, false id id`
- Esses rótulos são usados na formação das regras sintáticas e alguns *tokens* podem ser inseridos na **Tabela de Símbolos**
- Deve também reportar ao usuário a ocorrência de erros léxicos:
 - **fim inesperado de arquivo, mal formação de constantes (inteiras, reais, lógicas, literais), caracteres não permitidos no vocabulário terminal da linguagem.**

- 
- **Análise Sintática**: responsável por processar os tokens até reconhecer uma regra sintática que, posteriormente será analisada semanticamente, dado que a gramática é livre de contexto.
 - Pode ou não gerar uma estrutura sintática. Em muitos casos só aceita ou o programa.
 - Deve também reportar ao usuário a ocorrência de erros sintáticos: **then esperado,) esperado, ...**

- 
- Análise Semântica =
 - Análise de contexto +
 - Checagem de tipos +
 - Bookkeeping (gerenciamento da Tabela de Símbolos) +
 - Geração de Código Intermediário (RI)
 - As rotinas semânticas podem gerar alguma RI do programa ou gerar diretamente código objeto.
 - Devem reportar os erros de contexto e de tipos:
 - variável não declarada, número de parâmetros reais não bate com o número de parâmetros formais, tipo inteiro esperado, incompatibilidade de tipos, etc.
 - Se uma RI é gerada, então ela serve como entrada ao gerador de código para produzir um programa em linguagem de máquina ou montagem.
 - A RI pode, opcionalmente, ser transformada por um otimizador global para que um código de máquina mais eficiente seja gerado.

- 
- O. Global: melhorias que, em geral, independem da linguagem de máquina.
Por exemplo:

- eliminação de cálculos repetidos dentro de malhas trazendo-se para fora do loop.
- Eliminação de sub-expressões iguais:

$$A := B + C + D$$

$$E := B + C + F$$

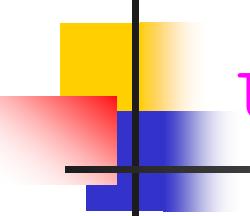


$$T1 := B + C$$

$$A := T1 + D$$

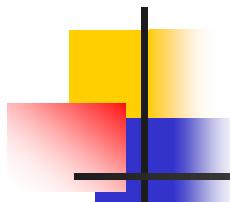
$$E := T1 + F$$

- Geração de Código: gera código relocável, absoluto ou de montagem.
- O. Local: melhorias no código objeto.



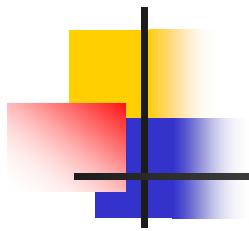
formas de organização de um compilador

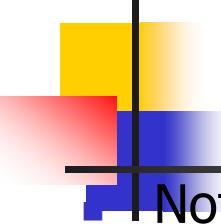
- As várias fases de um compilador podem ser executadas em seqüência ou ter sua execução combinada:
- **Compilação em Vários Passos:** A execução de algumas fases terminam antes de iniciar a execução das fases seguintes.
 - Vantagem: possibilidade de otimizações no código
 - Desvantagem: aumento do Tempo de Compilação
- **Compilação de um Passo:** O programa-objeto é produzido à medida que o programa-fonte é processado.
 - Vantagem: eficiência
 - Desvantagem: dificuldade de introdução de otimizações



Possibilidades de Organização

- Um único passo para Análise e Síntese
 - Todas as fases são intercaladas, nenhuma RI é gerada. Quando as linguagens permitem o comando: goto rótulo
.... rótulo
- Alguns compiladores deixam a informação de endereço em branco e só a preenchem quando encontram o endereço. Esta técnica se chama “backpatching” (remendo)
- Único passo + “Peephole Optimization” (local)
 - O otimizador toma o código de máquina gerado e olhando somente umas poucas instruções por vez melhora tal código.

- 
- Um único passo para Análise e Síntese da RI mais um passo para a Geração de Código
 - O front-end é independente de máquina. Facilidade para portar
 - Vários passos para a Análise
 - Vários passos para a Síntese
 - Nestas duas opções algumas fases terminam antes de outras.
 - Existe o aumento do tempo de compilação, pois os dados podem ser guardados em arquivos.
 - Como vantagem temos a possibilidade de gerar verdadeiras otimizações no código gerado ou na RI₅₁



Nosso Projeto

Notação **EBNF** para as regras da GLC vai definir os programas gramaticalmente corretos.

- Uso de uma ferramenta para gerar parser + analisador léxico: **JavaCC**.
- Semântica Estática (de tempo de Compilação) será fornecida oportunamente: realizada com inserção de código Java no arquivo de especificação do parser+lexer
- Não realizaremos a geração de código; só trataremos do Front-End do compilador
- Compilador de **um Passo**: todas as fases entrelaçadas; compilador dirigido por sintaxe (programa principal).