As fases de um compilador

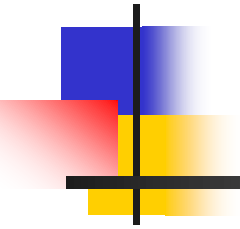

Paradigmas de LP

Métodos de Implementação de LP

Compilando um programa simples

estrutura de um compilador

formas de organização de um compilador

processo de execução de uma linguagem de alto-nível

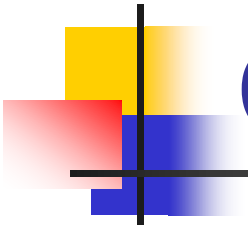

Compilador

- "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

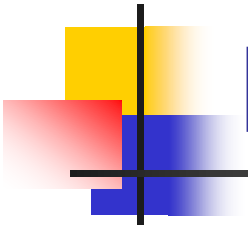

Paradigma lógico/declarativo

- 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

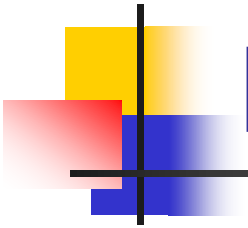

Paradigma funcional

- 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

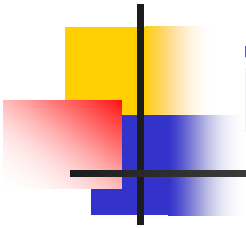

- Perspectiva do computador
- Baseado na execução seqüencial de comandos e na manipulação de estruturas de dados
- Exemplos de linguagens: FORTRAN, COBOL, ALGOL 60, APL, BASIC, PL/I, ALGOL 68, PASCAL, C, MODULA 2, ADA

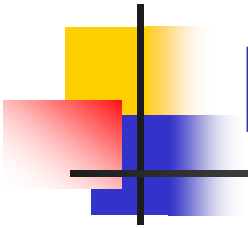

Paradigma orientado a objetos

- 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),

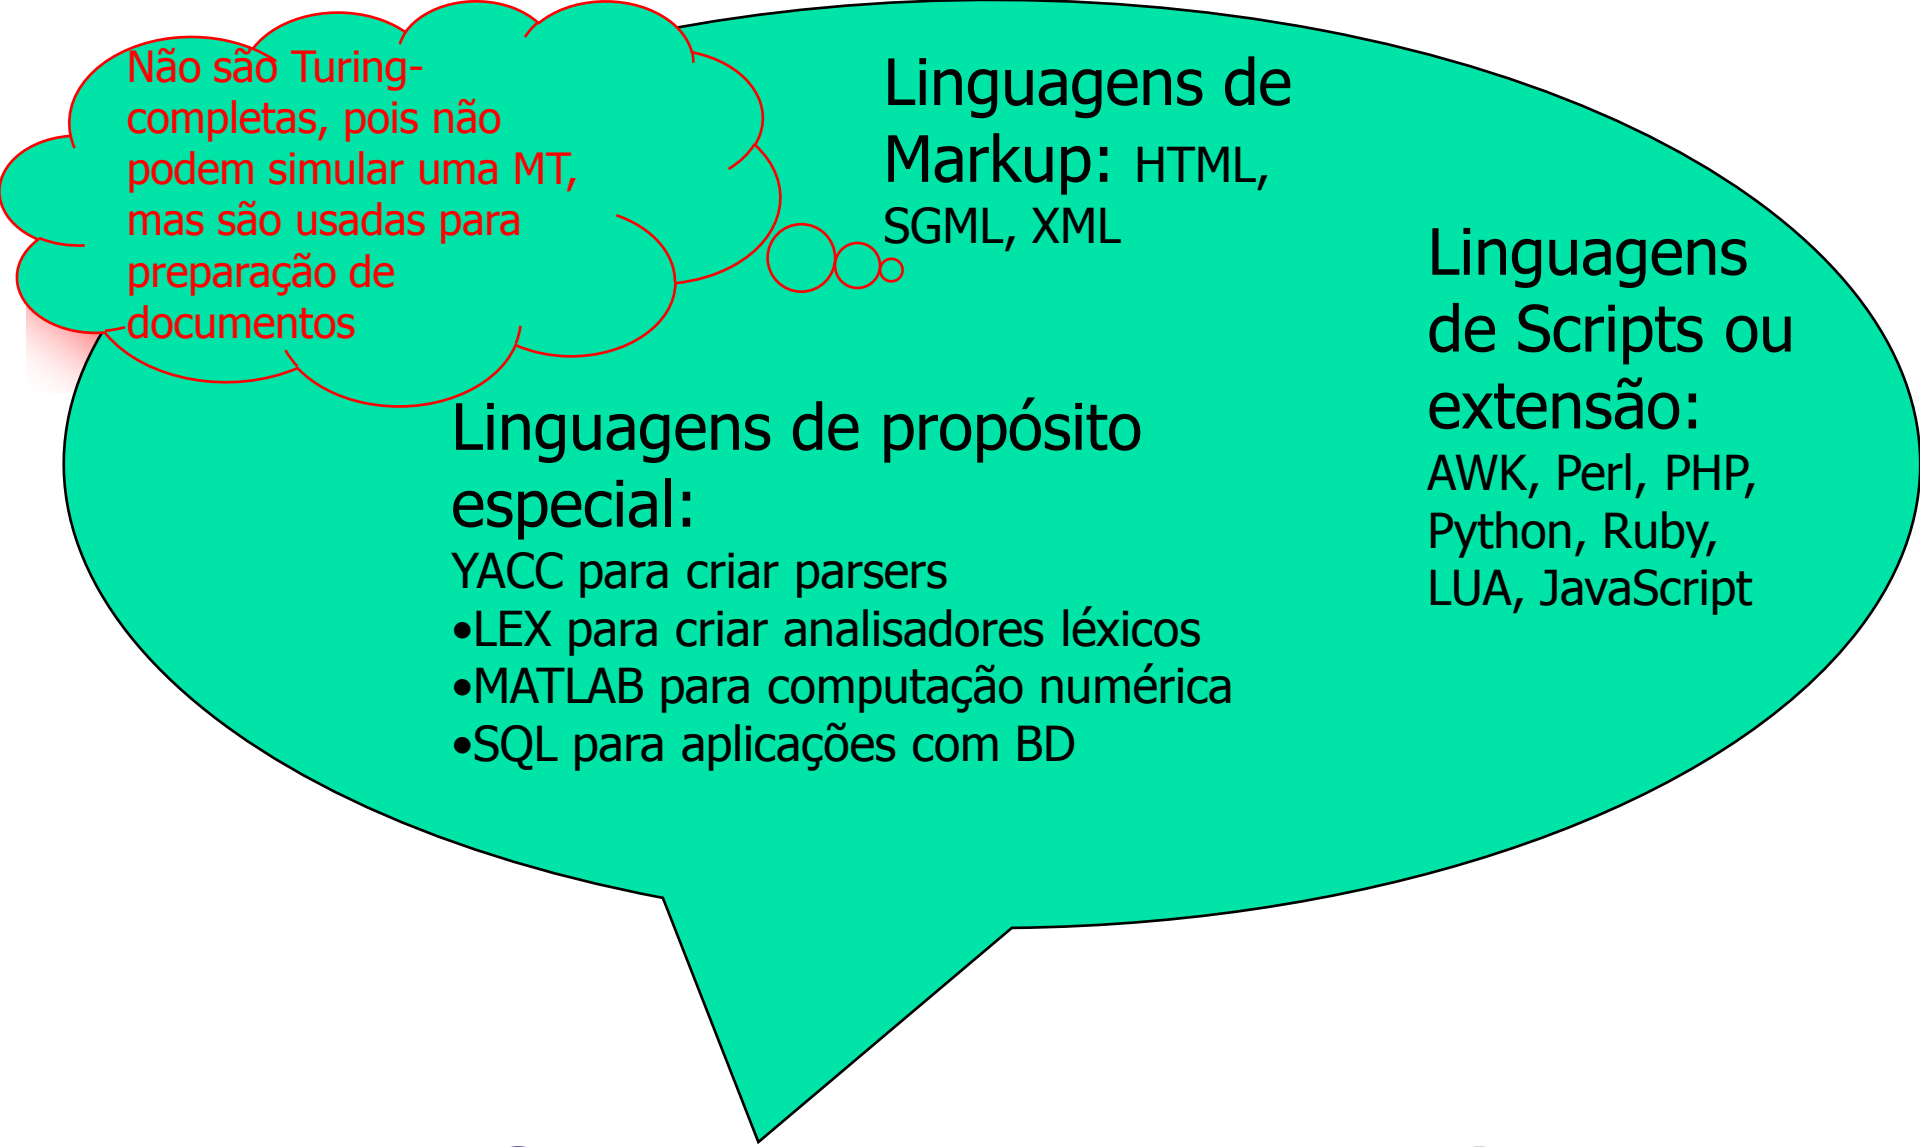

O que fazer com o resto das linguagens?

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
20   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

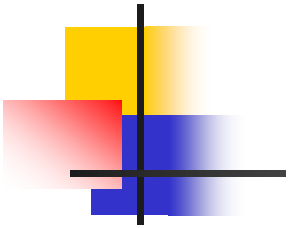

```
(defun gnome-doc-insert ()
  "Add a documentation header to the cu
Only C/C++ function types are properly
  (interactive)
  (let (c-insert-here (point))
    (save-excursion
      (beginning-of-defun)
      (let (c-arglist
            c-funcname
            (c-point (point))
            c-comment-point
            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 ⍵ 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←⍳0
[6]    M←¯1+2*31          ⍝ largest integer
[7]   L1:Q←N-⍴Z           ⍝ 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)⍴M  ⍝ 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×(⍟R)÷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

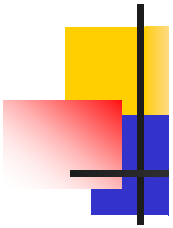

Algol, Pascal, Clu, Modula, Ada

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.

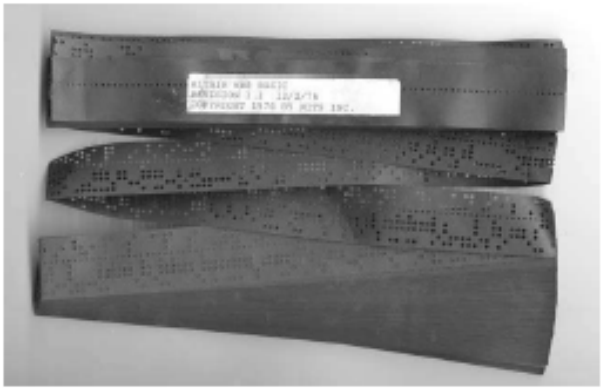

Simula, Smalltalk, C++, Java, C#

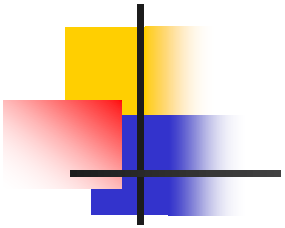

The object-oriented philosophy

```
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;
```

C

Efficiency for systems programming

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

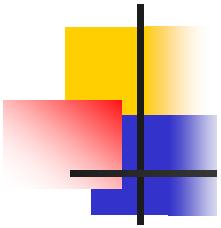

ML, Miranda, Haskell

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
}
```

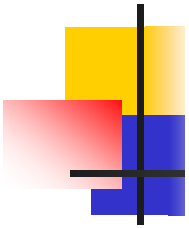

SQL

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());
```

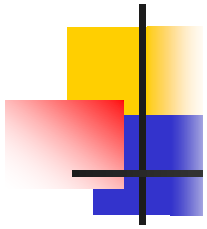

Prolog

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).
```

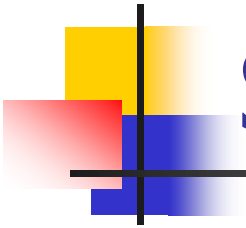

Sintaxe e semântica

- 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

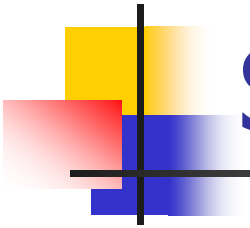

Sintaxe

- 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

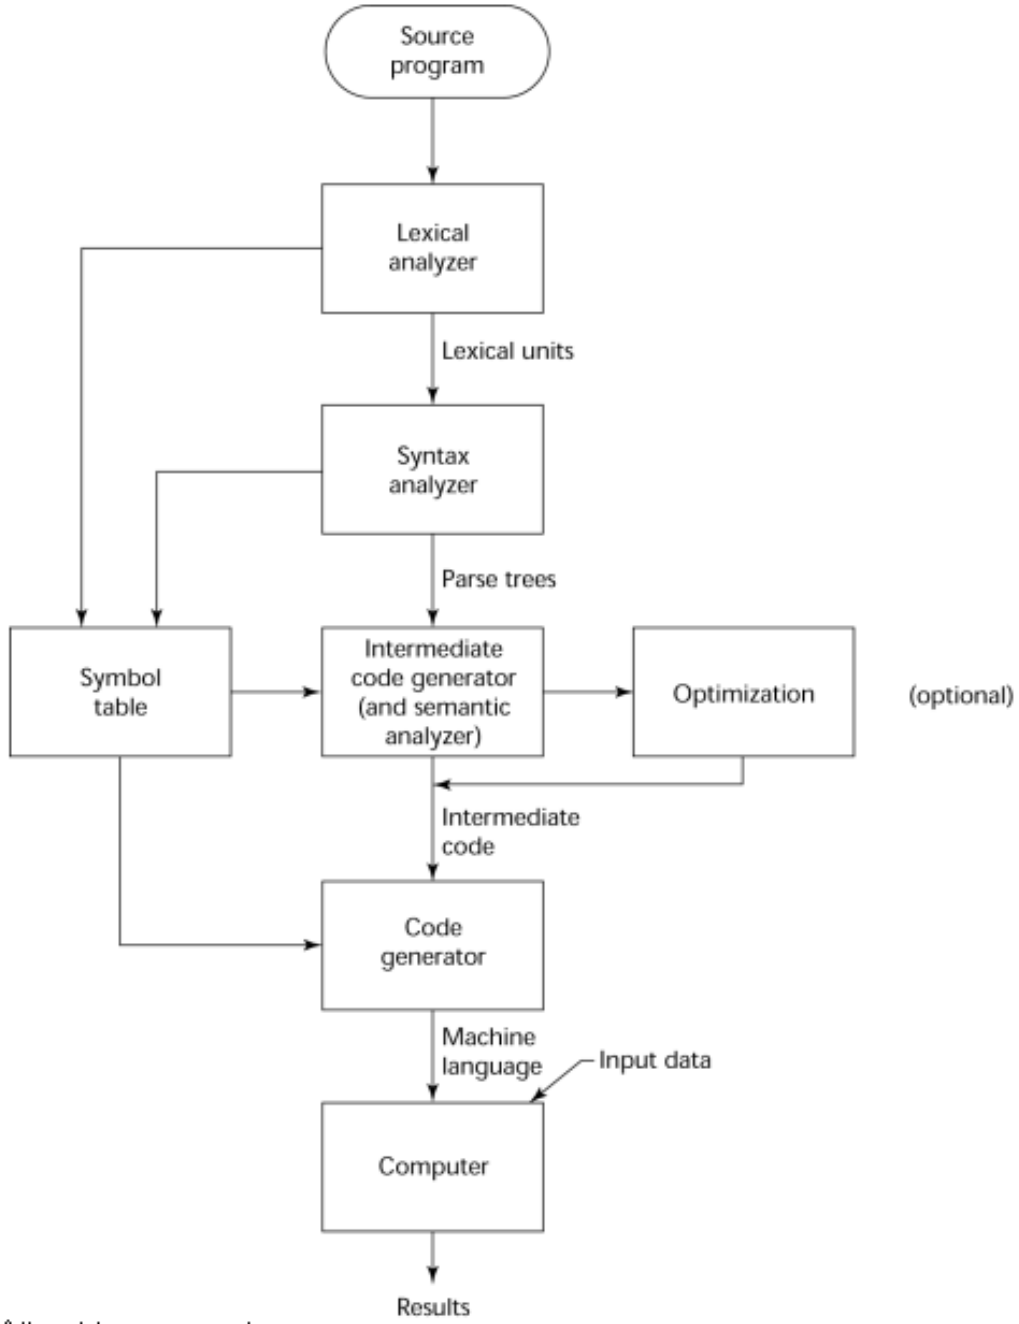

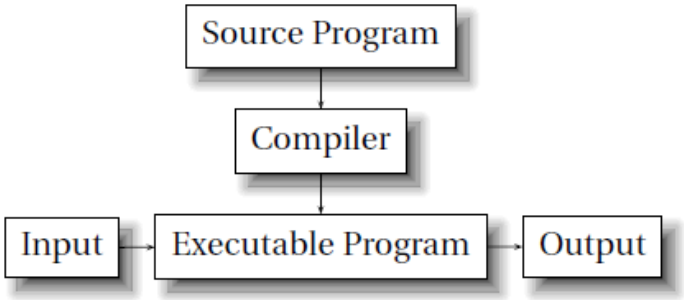

Tradução lenta
Execução rápida

Interpretador

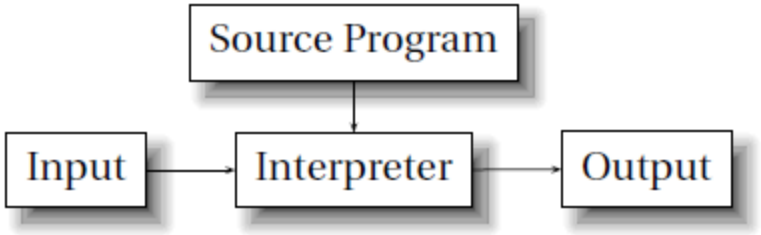

- Não há tradução
- Execução lenta (10 a 100 vezes mais lento que programas compilados)
- Frequentemente requer mais espaço
- Atualmente raro para as linguagens tradicionais, mas está havendo um retorno com as linguagens de script para a Web (por exemplo, JavaScript, PHP)

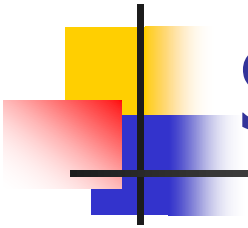

Sistemas Híbridos

- 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

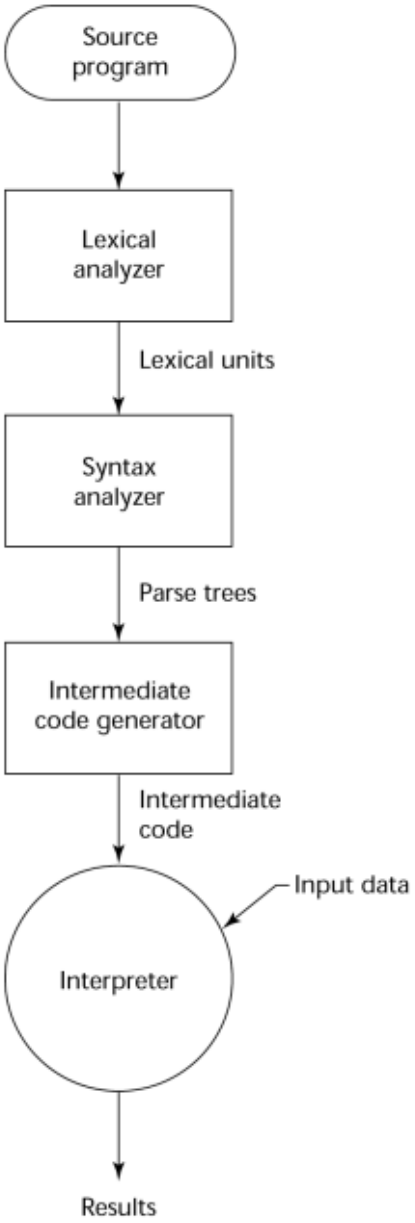

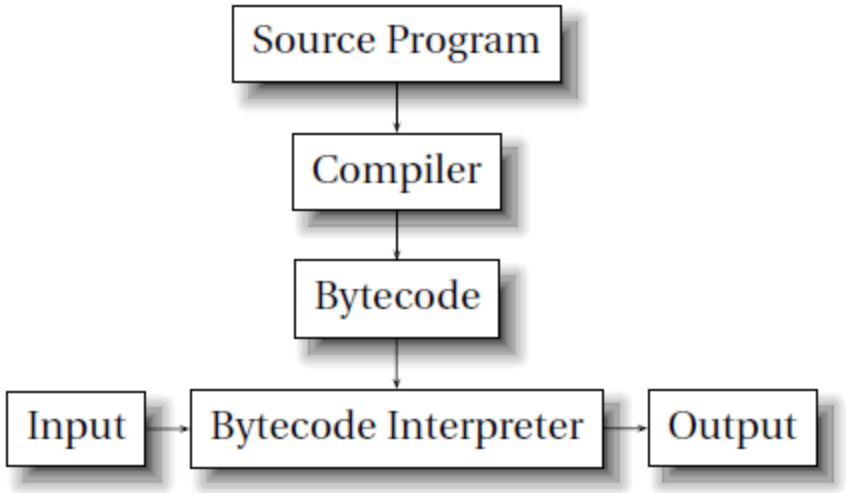

O conceito não é novo...Pascal P-code difundiu a linguagem Pascal

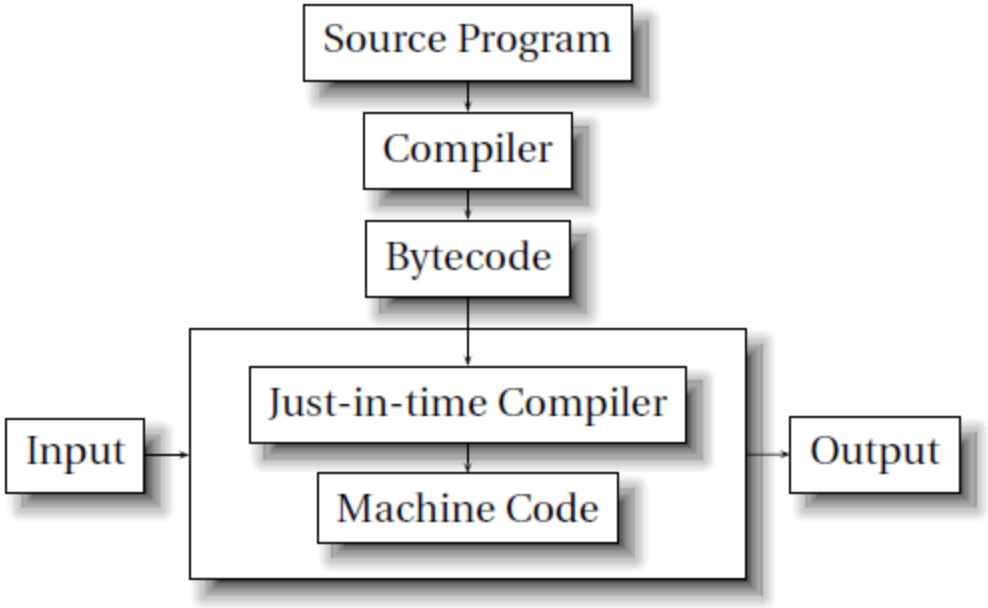

Compilador Just in Time

- 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/

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 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

Pal. Reservadas

Constantes

Símbolos Simples

Símbolos Compostos

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

Análise Sintática fornece uma uma árvore abstrata construída das regras da gramática

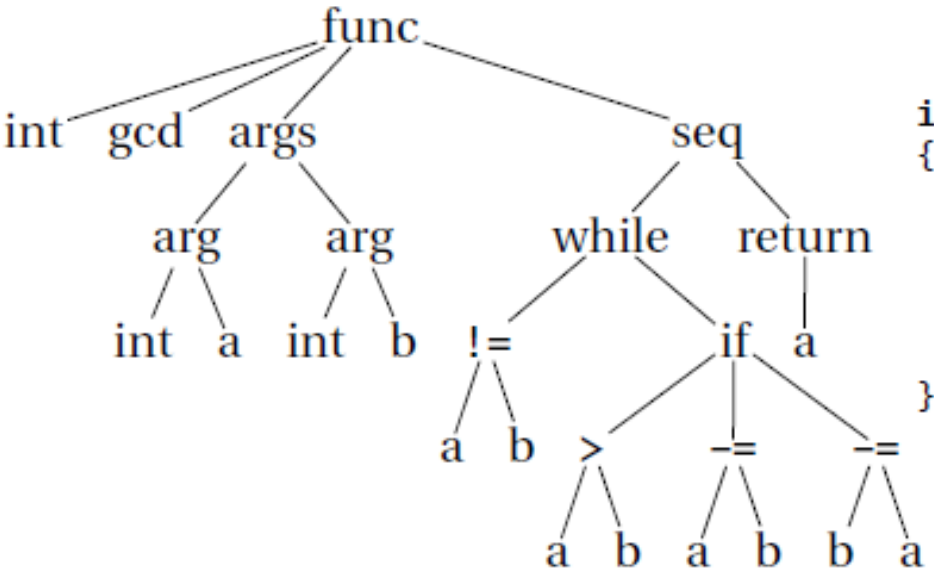


```
int gcd(int a, int b)
{
  while (a != b) {
    if (a > b) a -= b;
    else b -= a;
  }
  return a;
}
```

Análise Semântica resolve símbolos, com tipos checados

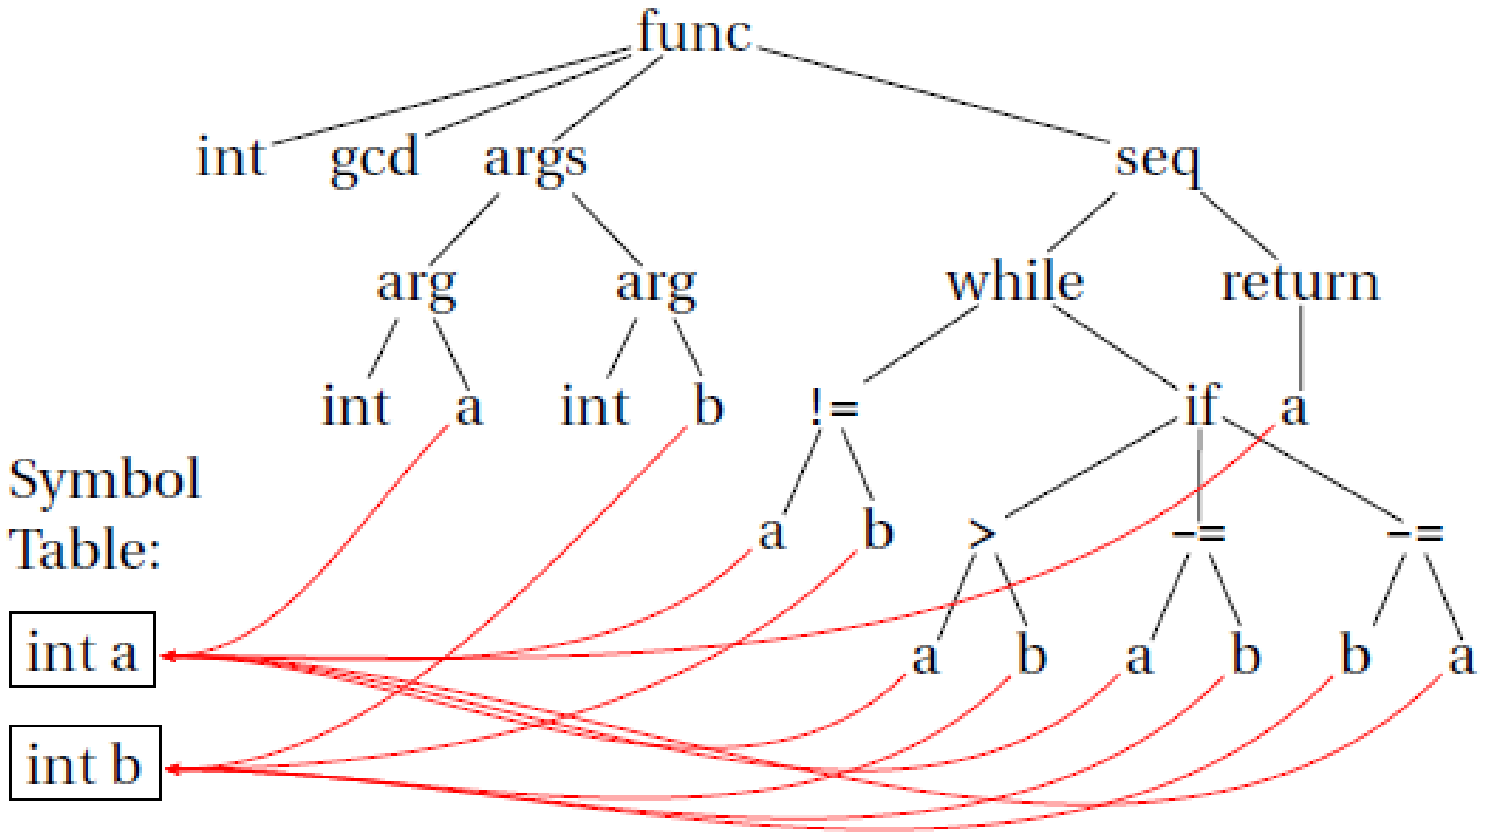

Tradução para uma linguagem intermediária (three-address code: linguagem assembler idealizada com infinitos registradores)

```
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

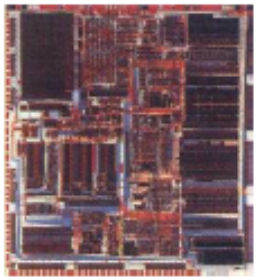

```
gcd:   pushl %ebp              % Save FP
       movl  %esp,%ebp
       movl  8(%ebp),%eax      % Load a from stack
       movl  12(%ebp),%edx     % Load b from stack
.L8:   cmpl  %edx,%eax
       je    .L3               % while (a != b)
       jle   .L5               % if (a < b)
       subl  %edx,%eax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

Possíveis Cenários de Execução de linguagens de alto nível

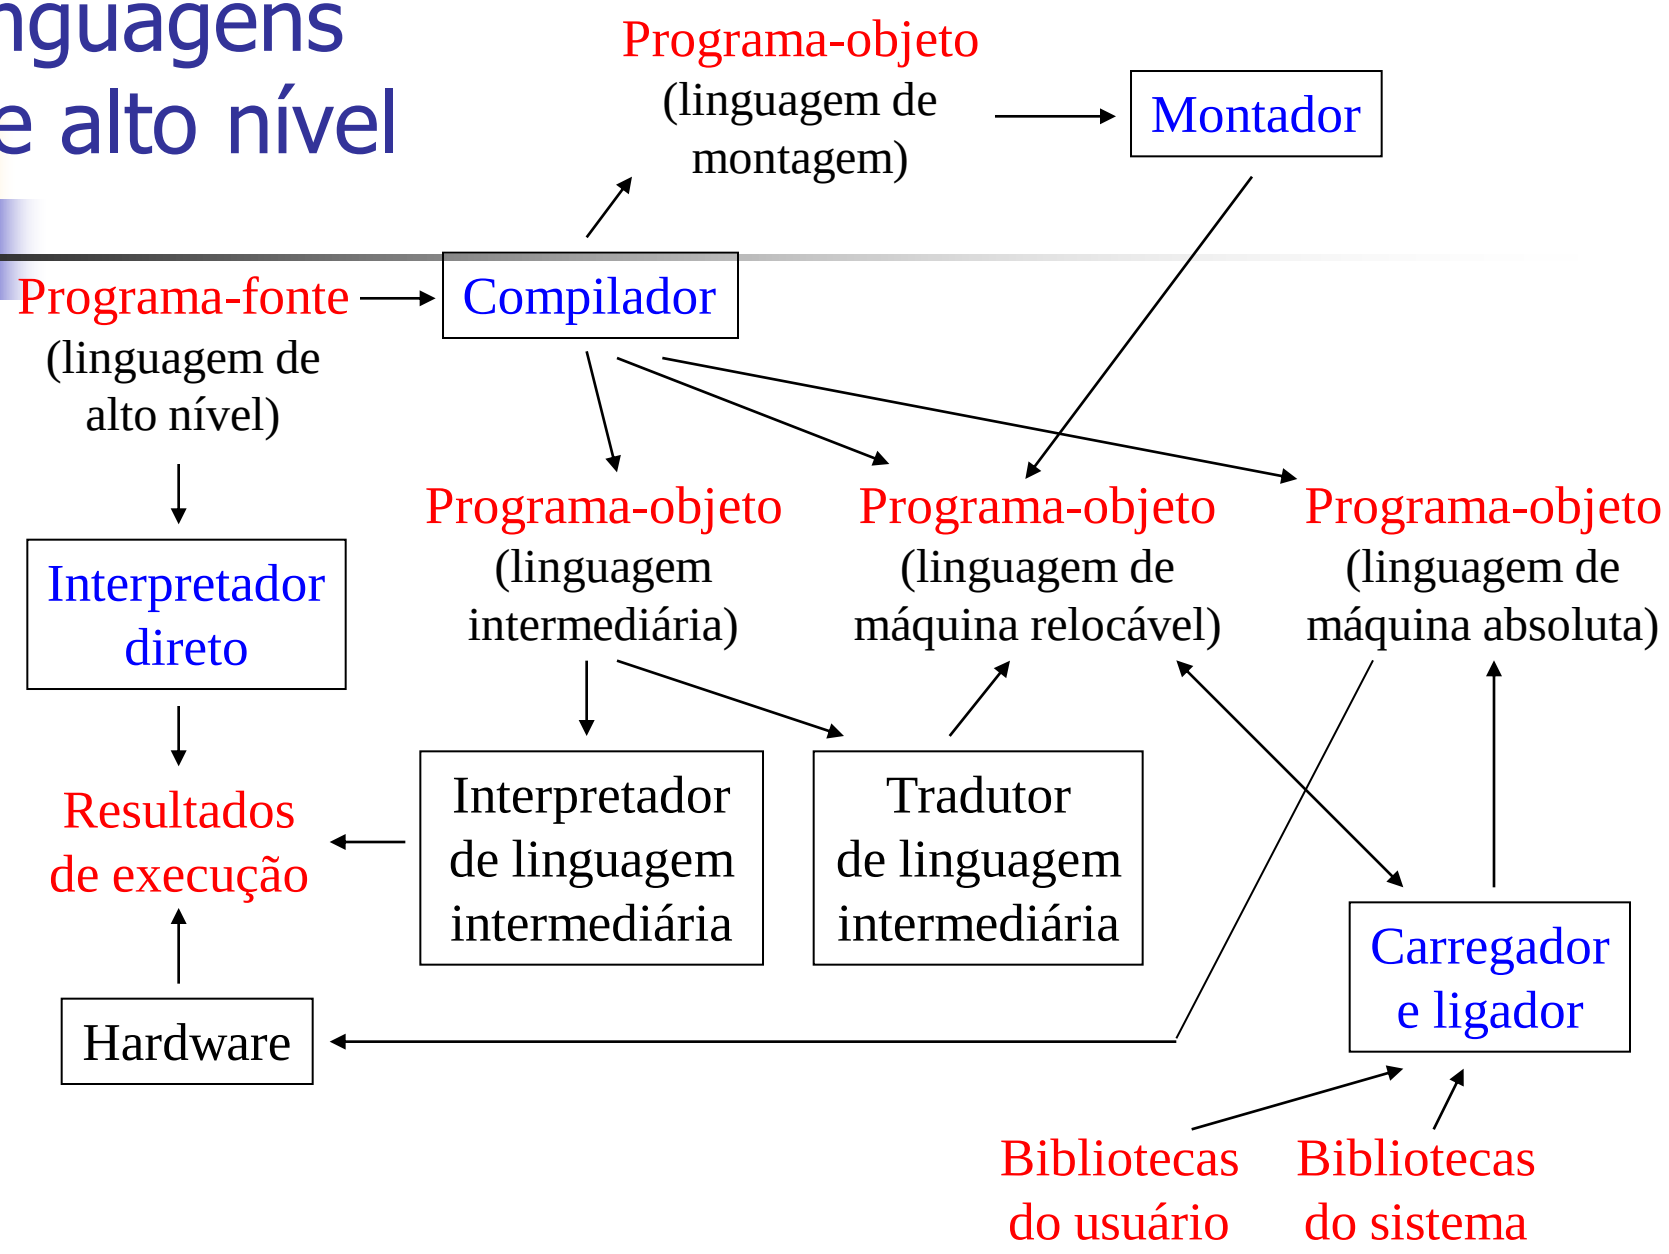

estrutura conceitual de um compilador (1)

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

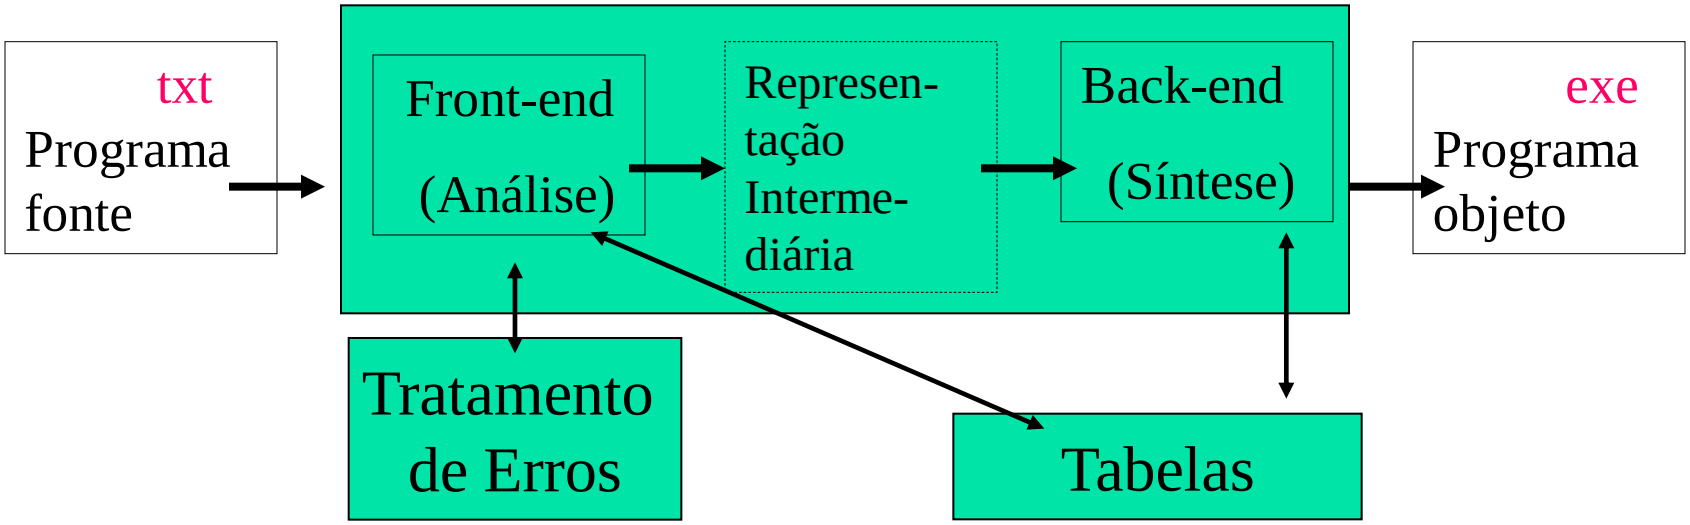

Fases da Síntese: Otimização Global, Geração de Código, Otimização Local

estrutura conceitual de um compilador (2)

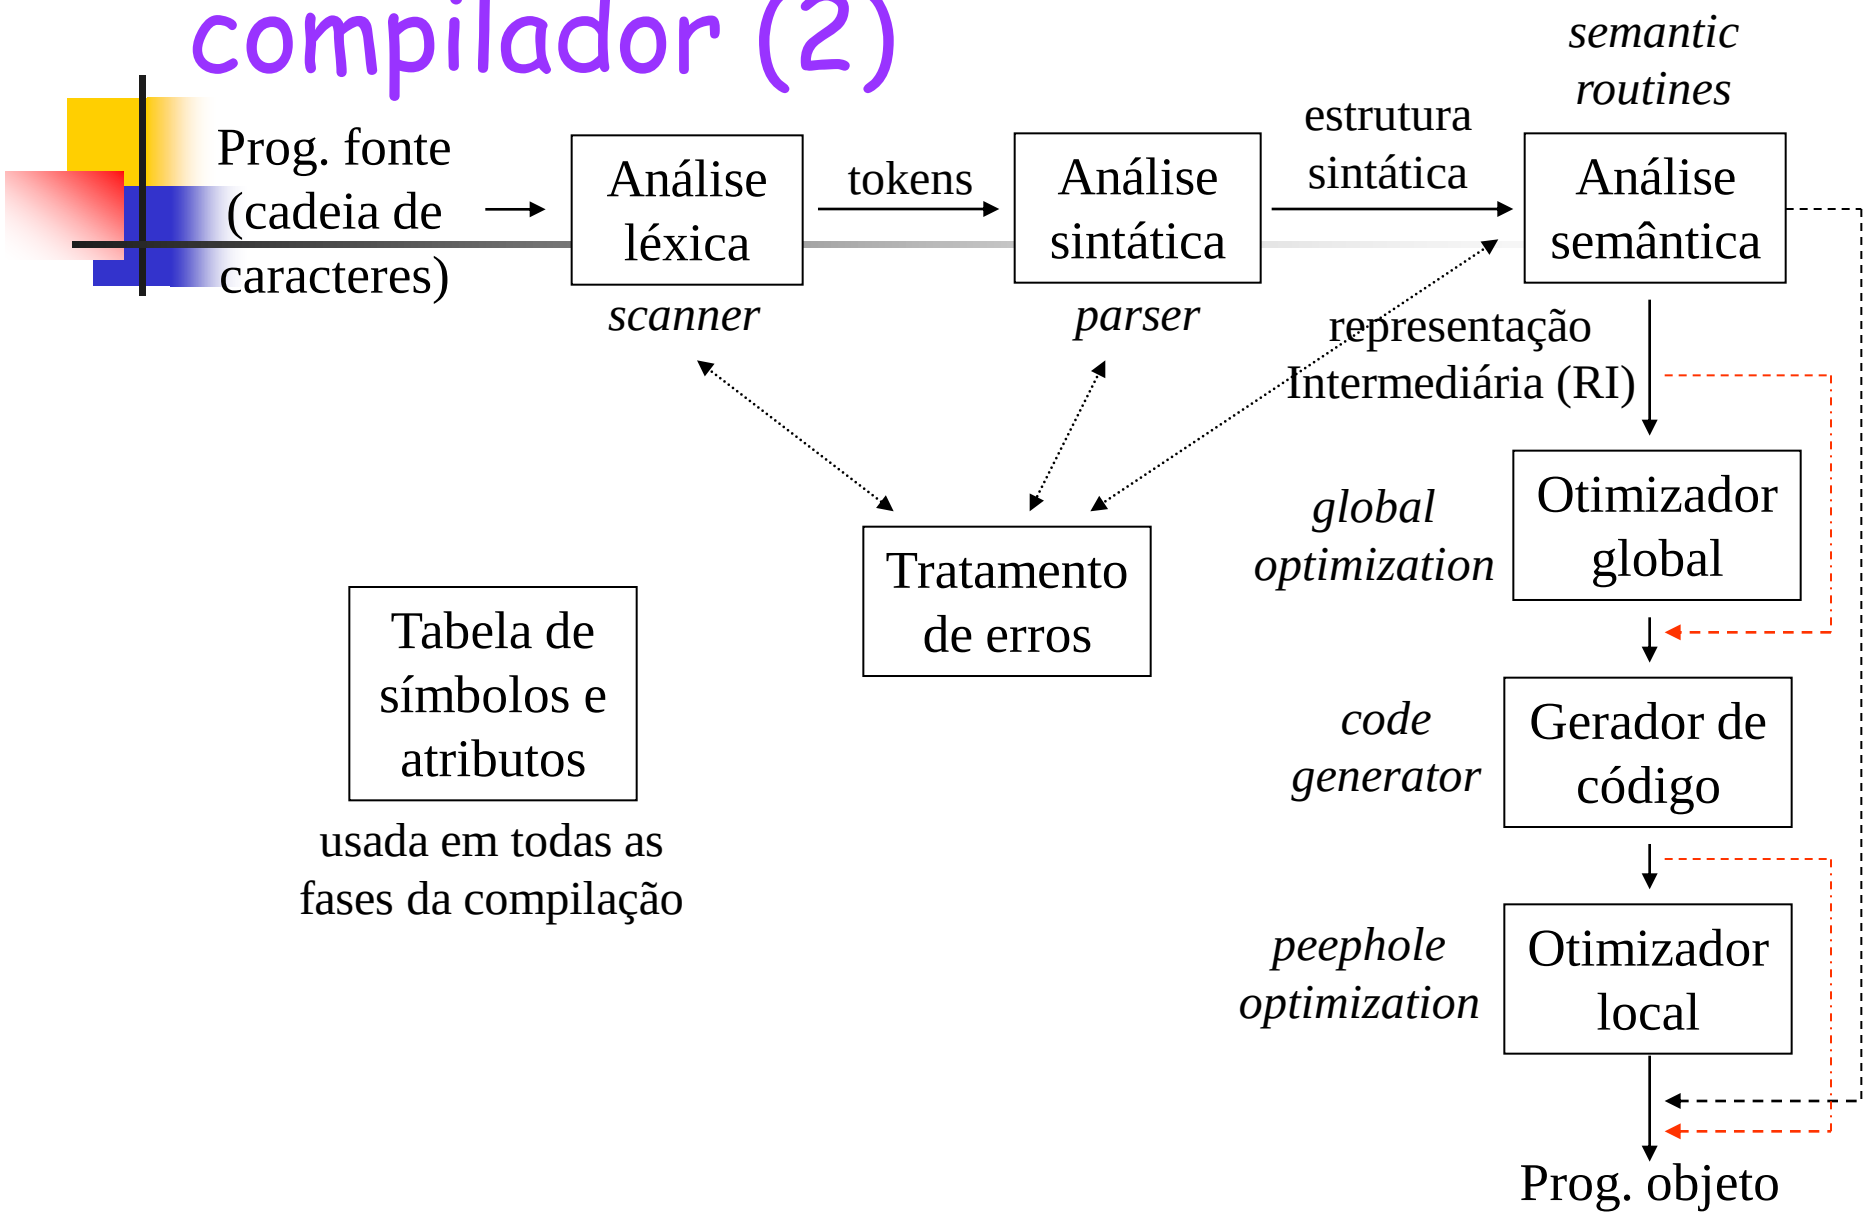

As fases e os erros que elas reportam

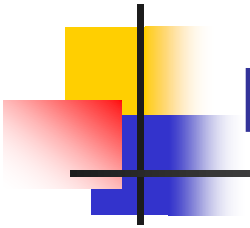

- Análise Léxica: responsável por ler o arquivo em que está armazenado o programa fonte (da esquerda para a direita) e por reconhecer os *tokens* (ou itens léxicos) e lhes dar um rótulo:
  - Palavras reservadas: begin, if, var, ... s_begin, s_if, s_var, ...
  - Identificadores: X, Y, Z, integer, boolean... 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.

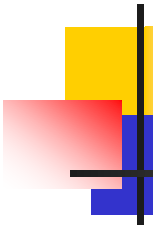

- Análise Sintática: responsável por processar os tokens até reconhecer uma regra sintática que, posteriormente será analisada semanticamente, dado que a gramática é livre de contexto.
    - Pode ou não gerar uma estrutura sintática. Em muitos casos só aceita ou o programa se este não conter erros.
-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

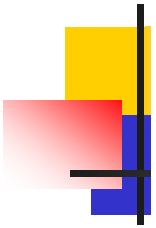

- Análise Semântica =
  - Análise de contexto +
  - Checagem de tipos +
  - Bookkeeping (gerenciamento da Tabela de Símbolos) +
  - Geração de Código Intermediário (RI)
- As rotinas semânticas podem gerar alguma RI do programa ou gerar diretamente código objeto.

- 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.

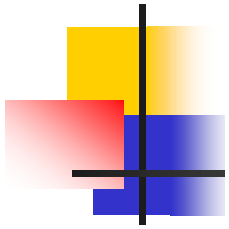

- O. Global: melhorias que, em geral, independem da linguagem de máquina. Por exemplo:
  - eliminação de cálculos repetidos dentro de malhas trazendo-se para fora do loop.
  - Eliminação de sub-expressões iguais:

```
A := B + C + D                T1 := B + C
E := B + C + F      ⟹        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

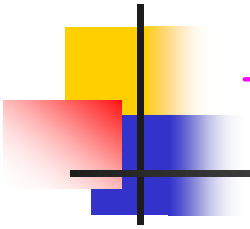

- As várias fases de um compilador podem ser executadas em seqüência ou ter sua execução combinada:
- Compilação em Vários Passos: A execução de algumas fases terminam antes de iniciar a execução das fases seguintes.
  - Vantagem: possibilidade de otimizações no código
  - Desvantagem: aumento do Tempo 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

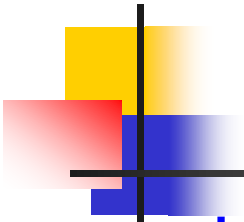

Possibilidades de Organização

- 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.

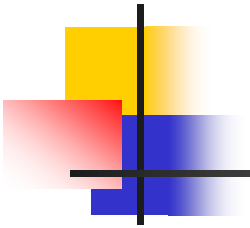

- Um único passo para Análise e Síntese da RI mais um passo para a Geração de Código
  - O front-end é independente de máquina. Facilidade para portar
- Vários passos para a Análise
- Vários passos para a Síntese
  - Nestas duas opções algumas fases terminam antes de outras.
  - Existe o aumento do tempo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

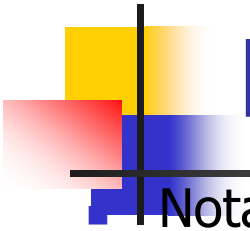

Nosso Projeto

- 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) e regras para Checagem de Tipos serão 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 é o parser).

Abrindo a caixa preta: compilador cruzado

Sistema Híbrido, precisa do Interpretador para MEPA

Pascal Simplificado com extensões individuais