Breve Histórico & Conceitos Básicos

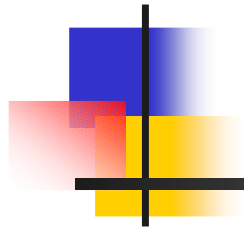

compiladores interpretadores montadores **filtros**

pré-processadores carregadores linkers

compilador cruzado (cross-compiler)

auto-compilável (bootstraping) auto-residente

compiler compilers (ou translator writing systems, ou compiler generators)

estrutura de um compilador

formas de organização de um compilador

processo de execução de uma linguagem de alto-nível

Linha do Tempo

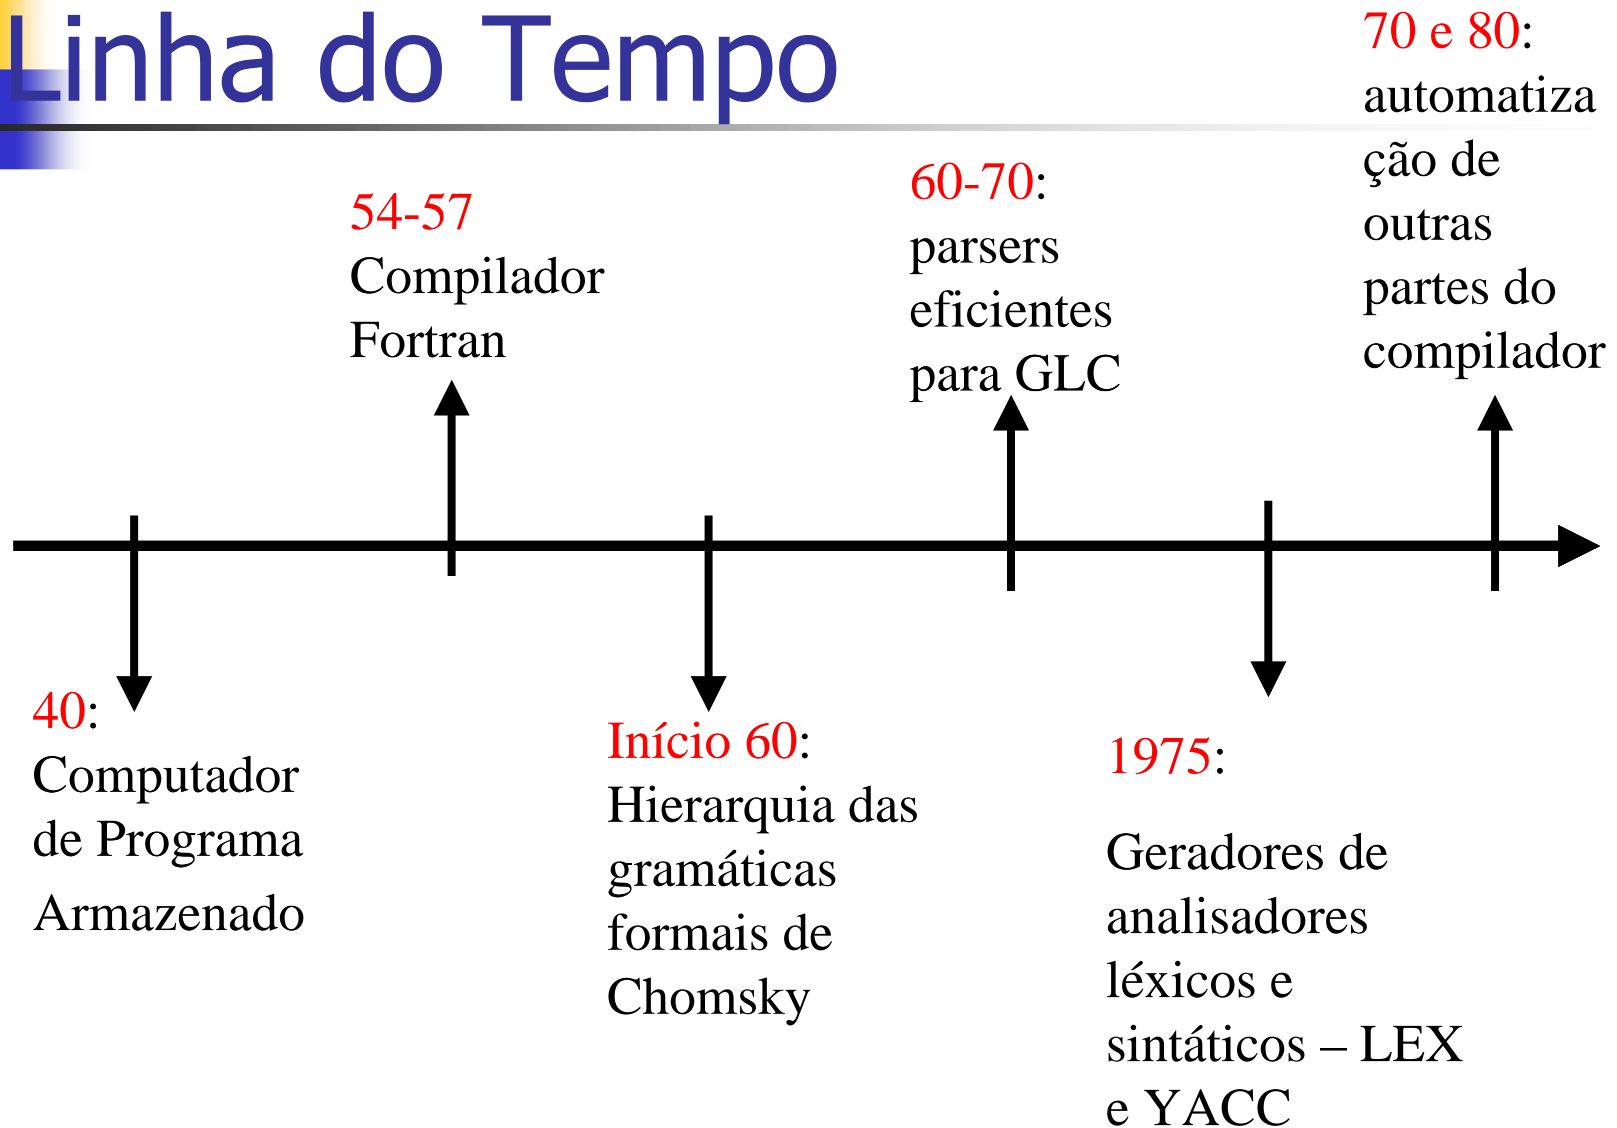

Histórico

- Computador de programa armazenado (von Neumann) – final da década de 40
  - Inicialmente os programas eram escritos em código de máquina (computadores tinham pouca memória)
- Linguagem de montagem para facilitar a programação
  - Necessidade de um programa (montador) para traduzir para código de máquina
- Próximo passo: linguagem de alto nível
  - Temor: que fosse impossível ou que o código objeto fosse tão ineficiente que seria inútil!

Histórico

- Primeira Linguagem de alto nível (Fortran) e seu compilador, graças a Backus, entre 1954 e 1957
  - Muito esforço, pois grande parte dos processos de tradução ainda não eram entendidos naquele tempo,
  - Entretanto com relação a otimização de código estava a frente no seu tempo.

- Chomsky inicia estudos da estrutura da linguagem natural (inglês) no fim dos 50 – início dos 60´s
  - Complexidade das gramáticas e os algoritmos para reconhecê-las: tipo 0, 1, 2, 3.

- Determinação de algoritmos eficientes para reconhecer gramáticas livres de contexto: 1960 e 1970

Histórico

- Vantagens da separação entre reconhecimento de tokens de uma linguagem e suas regras (sintaxe)
  - levou ao uso de métodos para expressar os tokens (uso de autômatos finitos e expressões regulares)
- Com uma maior compreensão da análise sintática surgiram métodos para automatizar partes do desenvolvimento de compiladores
  - Geradores de analisadores sintáticos (YACC – unix em 1975)
- O estudo dos autômatos finitos
  - Geradores de analisadores léxicos (Lex – unix em 1975)
- Década de 70 e 80 houve projetos para automatizar a geração de outras partes do compilador (geração de código)

Compilador

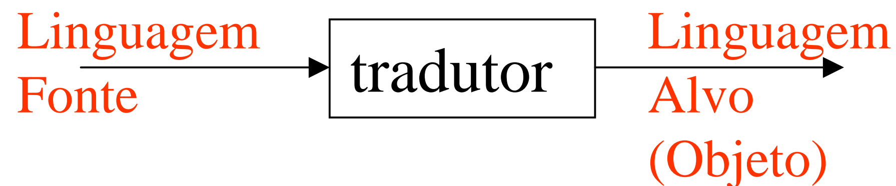

Compilador é um tradutor que transforma automaticamente uma linguagem de programação de alto nível para alguma outra forma que viabilize sua execução

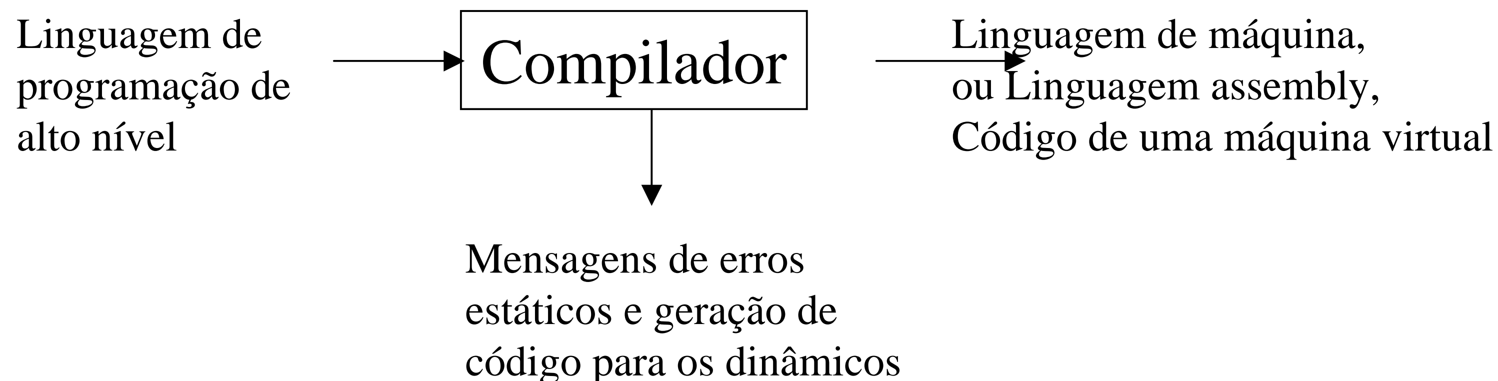

Tarefas

- Deve transformar a L.F. em uma L.A. equivalente
- Deve informar os erros do programa fonte, caso existam
- Permite que os programas sejam independentes de máquina (portabilidade)

Propriedades de um bom compilador

- Principal: gere código corretamente
- Seja capaz de tratar de programas de qualquer tamanho que a memória permita
- Velocidade da compilação não é a característica principal
- Tamanho do compilador já não é mais um problema atualmente
- User-friendliness se mede pela qualidade das mensagens de erros
- A importância da velocidade e tamanho do código gerado depende do propósito do compilador --- velocidade do código vem em primeiro lugar

Tecnologia de Compiladores

- Os primeiros compiladores foram construídos *ad hoc*, sem técnicas, eram vistos como processos complexos e de alto custo
  - Hoje, o processo é bem entendido, sendo a construção de um compilador uma rotina, embora a construção de um compilador eficiente e confiável seja ainda uma tarefa complexa.
- A tecnologia de compiladores é largamente empregada em muitas áreas:
  - linguagens de formatação de textos (nroff, troff, latex, sgml)
  - "silicon compilers" que transformam uma linguagem de especificação de circuitos VLSI em um projeto de circuitos
  - linguagens de acesso a banco de dados (query languages)
  - editores de texto orientados a sintaxe
  - analisadores estáticos de programa que podem descobrir variáveis não inicializadas, código que nunca será executado, etc.
  - checadores de entrada de dados em qualquer sistema
  - interpretadores de comandos de um S.O.

Formas de Classificar Compiladores

- De acordo com o tipo de linguagem objeto gerado
- De acordo com o formato do código objeto gerado

Alternativas para a saída de um compilador (1/4)

- Os compiladores podem ser distinguidos de acordo com o tipo de linguagem objeto que eles geram:
  - Código de Máquina Puro: geram código para um conjunto de instrução de máquina sem assumir a existência de rotinas do SO ou rotinas de biblioteca.

    Isto quer dizer que o compilador não está contando com nenhum "ambiente de execução"

    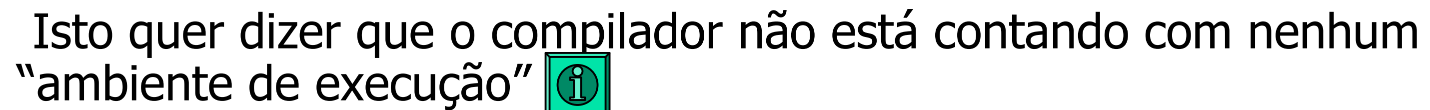

    Esta abordagem é rara e é utilizada para implementar as linguagens que serão utilizadas para escrever o SO e outros programas de baixo nível.
  - Código de Máquina Aumentado: geração de código para uma arquitetura aumentada com as rotinas do SO (salvar registradores, acessar BIOS) e de suporte à linguagem (I/O, alocação dinâmica, e funções matemáticas) que devem ser carregadas com o programa.

    A combinação de código de máquina do compilador + rotinas do SO + rotinas de suporte é chamada "Máquina Virtual".

    Esta abordagem é mais freqüente.

Alternativas para a saída de um compilador (2/4)

- Código de Máquina Virtual: caso extremo de definição de uma máquina virtual em que o código gerado é composto inteiramente de instruções virtuais: geração para uma máquina hipotética.

  Existe um interpretador que roda sobre o hardware físico e emula o hardware de um projeto diferente.

  Abordagem atrativa pela facilidade de transportar para máquinas diferentes.

  Se a máquina virtual é simples, escrever um interpretador é tarefa fácil (geralmente é a escolha para um "compilador didático")

Alternativas para a saída de um compilador (3/4)

Compiladores também podem ser distinguidos pelo formato do código objeto que eles geram:

- Linguagem Assembly (Montagem): esta abordagem simplifica a tradução pois várias decisões são deixadas para o montador (endereço de jumps, por exemplo).
  - Pode-se checar a saída e verificar a corretude (assembly é mais legível). É útil para cross-compilers (compilador que roda em uma máquina e gera código para outra) pois gera um arquivo facilmente transportável.

  Esta abordagem não é comum, pois precisa de um passo adicional feito pelo montador, que é lento. Algumas vezes o código em assembly é um produto extra de alguns compiladores (psedo-assembly languages) para checagem de corretude.

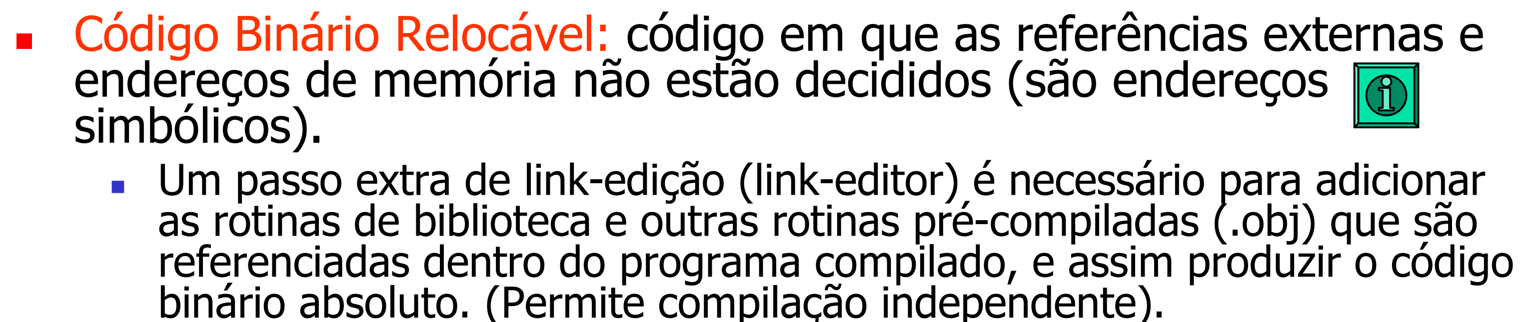

- Código Binário Relocável: código em que as referências externas e endereços de memória não estão decididos (são endereços simbólicos).
  - Um passo extra de link-edição (link-editor) é necessário para adicionar as rotinas de biblioteca e outras rotinas pré-compiladas (.obj) que são referenciadas dentro do programa compilado, e assim produzir o código binário absoluto. (Permite compilação independente).

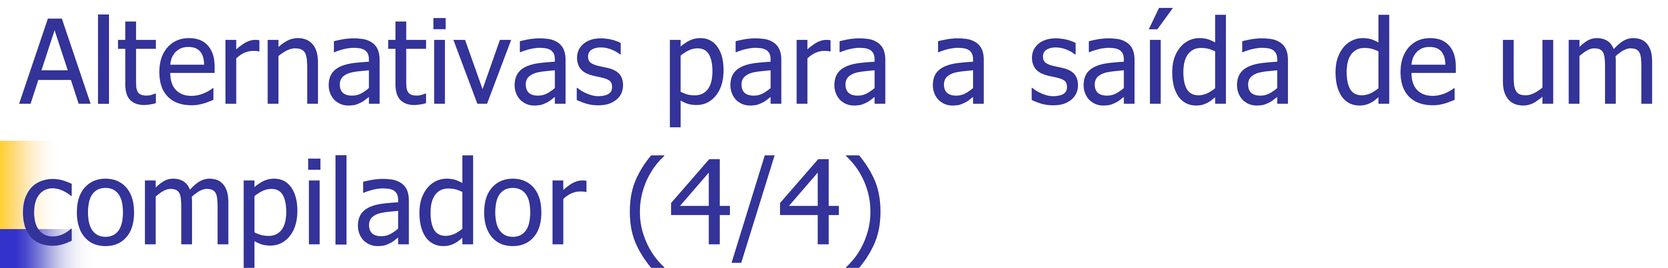

Alternativas para a saída de um compilador (4/4)

O código relocável e o código assembly permitem compilação modular, interfaces com outras linguagens (cross-languages references, isto é, chamadas de rotinas em assembly ou em outras linguagens de alto nível --- Amzi Prolog) e rotinas de biblioteca.

- Imagem de Memória (Load-and-Go): a saída do compilador é carregada diretamente na memória e executada ao invés de ser deixada em um arquivo. Esta abordagem é rápida pois não exige link-edição, mas o programa deve ser recompilado a cada execução. Por ser mais rápido é útil para a fase de depuração e uso de estudantes novatos. Exemplo: Turbo Pascal.

Montadores, Filtros, e Pré-processadores

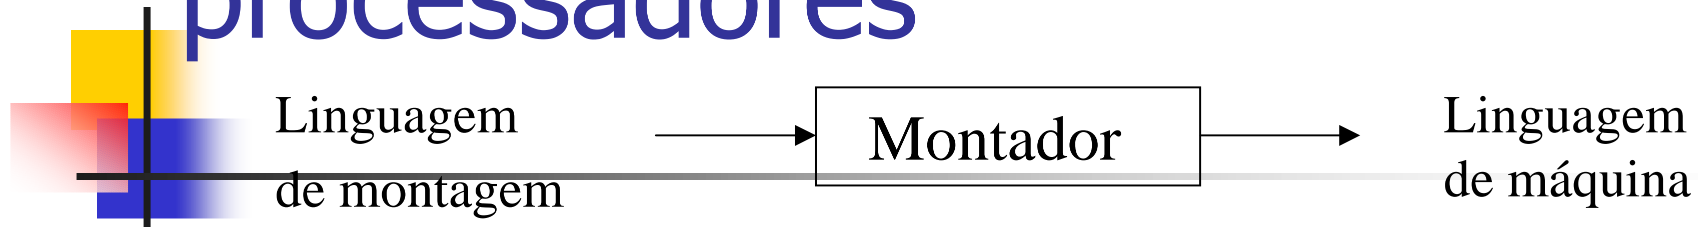

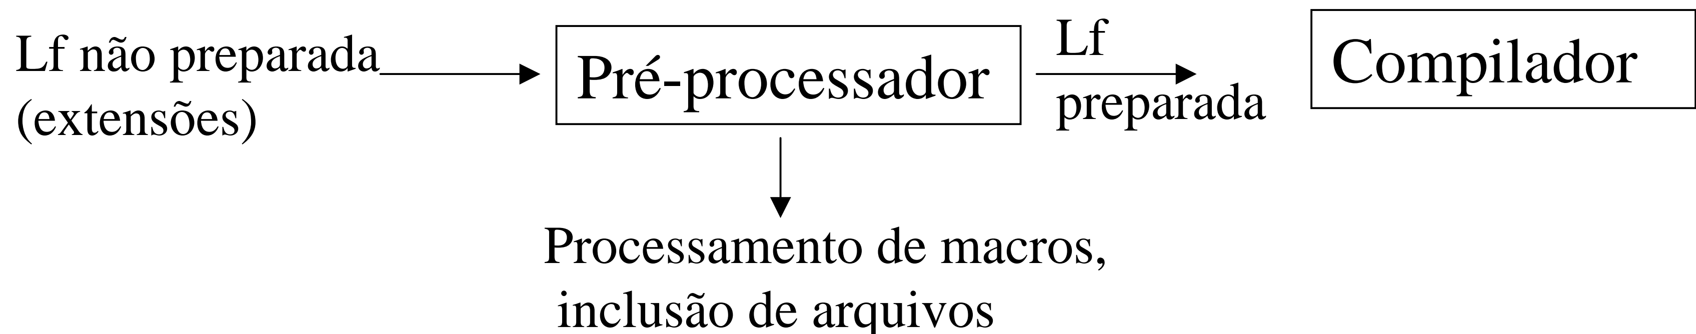

Interpretadores

- Em vez de traduzir de uma vez o programa-fonte para então executá-lo, decodifica unidades básicas do programa para executá-las imediatamente (não mantém o código-objeto para sempre). Este é um enfoque de interpretação (TRADUZ-EXECUTA), porém consome muito tempo. Ex: BASIC.
- Se a velocidade de compilação for requisito importante prefere-se um compilador
  - Dez ou mais vezes mais rápido que um interpretador
- Uma estratégia mais eficiente envolve a aplicação de técnicas de compilação:

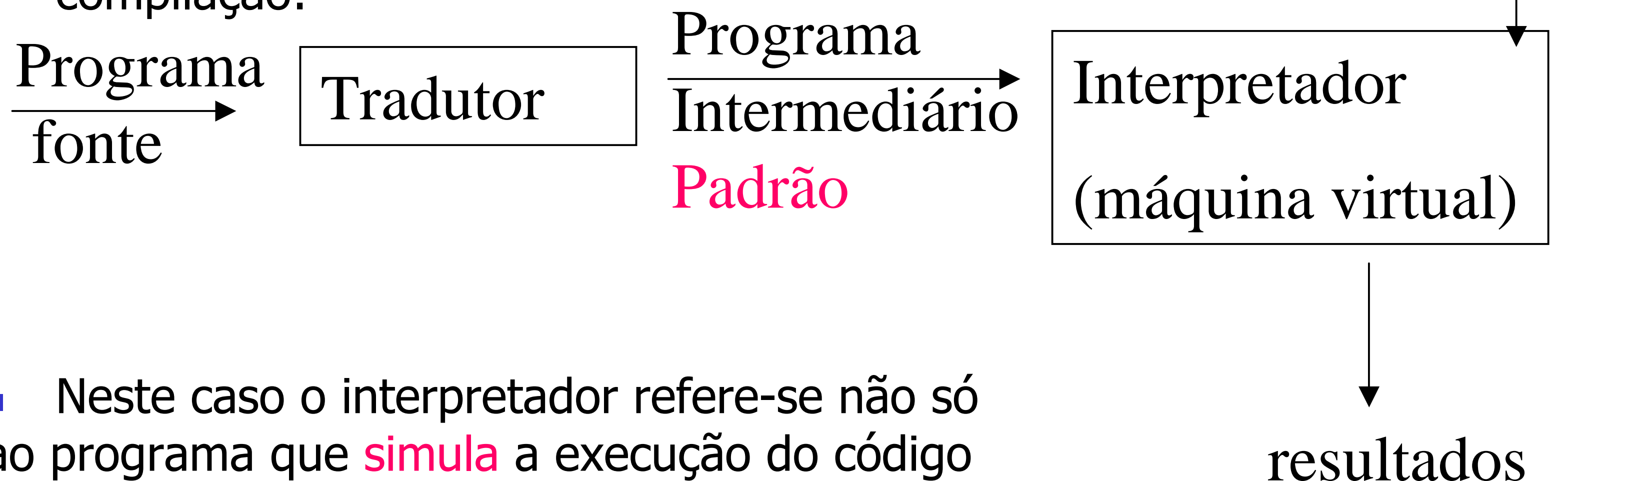

- Neste caso o interpretador refere-se não só ao programa que simula a execução do código Intermediário, mas a todo o processo.

Compilador cruzado, auto-residente, auto-compilável $C^{LF \quad LO}_{LD}$

- Compilador cruzado roda em uma máquina e produz código para outra.
- Compilador auto-residente (ou nativo) é executado na mesma máquina para qual gerou código objeto.
- Compilador auto-compilável. Porque alguém faria um compilador para uma linguagem sendo implementado nela própria???? Lisp foi a primeira linguagem a ter um em 1962
  - Há vantagens? Facilita o transporte de uma máquina para outra. Suponha que queremos uma linguagem L para as máquinas A e B.
- 1o. Passo: $C^{S \quad A}_{A}$ Pode ser escrito numa linguagem aceita por A, assembly por exemplo

- 2o. Passo: $C_S^{L\ A}$

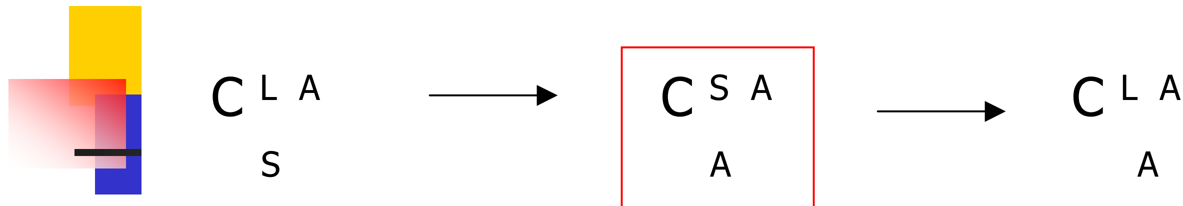

Agora suponha que desejamos ter $C_B^{L\ B}$

Como temos $C_S^{L\ A}$ fica mais fácil convertê-lo em $C_L^{L\ B}$

do que escrever um outro compilador (só temos que mudar a geração de código). Processo em dois passos:

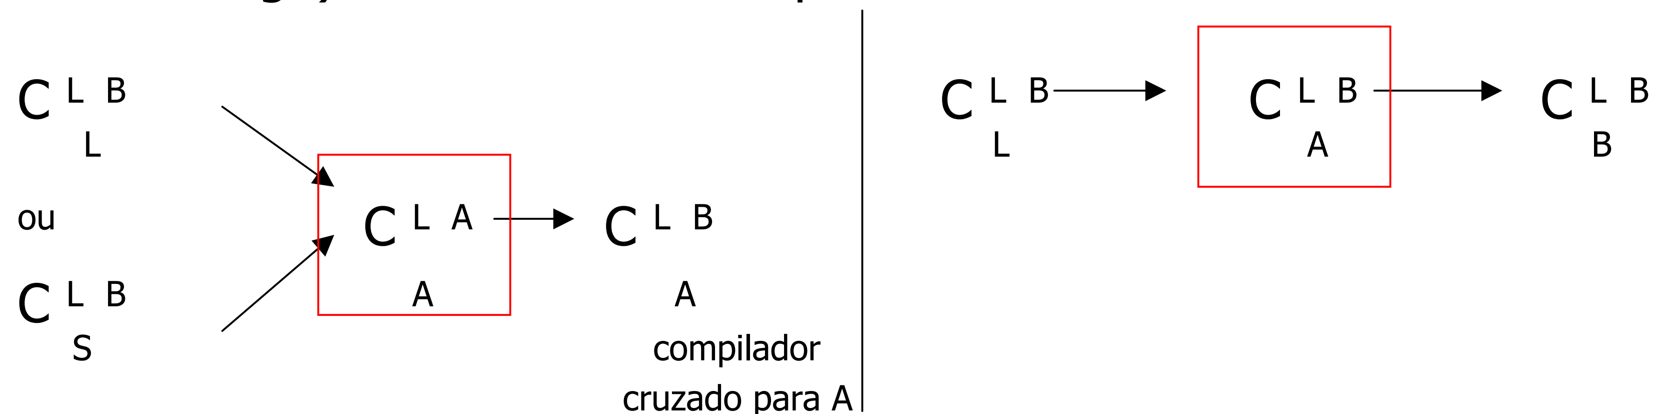

Compiler Compilers

- Ferramentas para auxiliar o desenvolvimento de compiladores:
  - geradores de analisadores léxicos (LEX, por exemplo)
  - geradores de analisadores sintáticos (YACC, por exemplo, possui também chamadas de rotinas para as ações semânticas e geração de código)
  - sistemas complexos que produzem o compilador inteiro (toolkit)

http://www.thefreecountry.com/programming/compilerconstruction.shtml

Ambiente de Execução

Infra-estrutura com que o programa objeto conta para sua correta execução:

- uma interface com o SO
- um conjunto de rotinas que deixam disponíveis os recursos oferecidos pela linguagem (rotinas aritméticas, trigonométricas, pacotes gráficos, etc.)
- um conjunto de procedimentos de manutenção do ambiente: gerenciamento de memória, da passagem de parâmetros, do controle da recursividade, etc.

Pascal P-Compiler

- Escrito por um grupo encabeçado por N. Wirth.
- Este compilador gera código chamado P-Code para uma máquina virtual à pilha.
- Problema: a velocidade era 4 vezes maior que o código compilado, mas podemos traduzir o P-Code para um código de máquina real.
- Este método difundiu o Pascal (Pascal UCSD) e o tornou disponível para uma grande variedade de máquinas.

- http://en.wikipedia.org/wiki/P-Code

Stack Machine X Register Machine

- No passado máquinas a pilha reservavam uma parte da memória principal para avaliar expressões. Esta implementação era mais lenta que o uso de registradores pois requer muitas referências à memória principal.
- Máquinas como Lilith, Burroughs e HP usam um pequeno array de registradores rápidos para implementar a pilha de expressões.
- Uma máquina a pilha pode ser mais rápida do que máquinas baseadas em registradores, pois necessitam de poucas instruções.
- Pascal Simplificado permite procedimentos recursivos e seu uso está intimamente relacionado ao uso de pilhas.
- Máquinas a pilha suportam efetivamente linguagens de alto nível estruturadas por blocos (proc. e funções).

Exemplo de Código Binário Relocável

Duas classes de instruções precisam de mais informações:

referências a endereços de variáveis e funções externas.

referências a endereços de memória, por exemplo:

b:= a + 2 → linguagem de alto nível

compilador gera código assembly

```
MOV a, R1
ADD #2, R1
MOV R1, b
```

Pode ser carregado a partir de uma posição L de memória

assembler/compilador gera código de máquina relocável

cod.	R1		
0001	01	00	00000000 *
0011	01	10	00000010
0010	01	00	00000100 *

acesso direto

acesso imediato

* bit de relocação, associado a cada operando no cod. relocável

link editor gera código de máquina absoluto e escolheu L = 15

0001	01	00	00001111	→ end. de a (15)
0011	01	10	00000010	
0010	01	00	00010011	→ end. de b (19)

Tabela de símbolos do montador

a	0
b	4

Execução de linguagens de alto nível

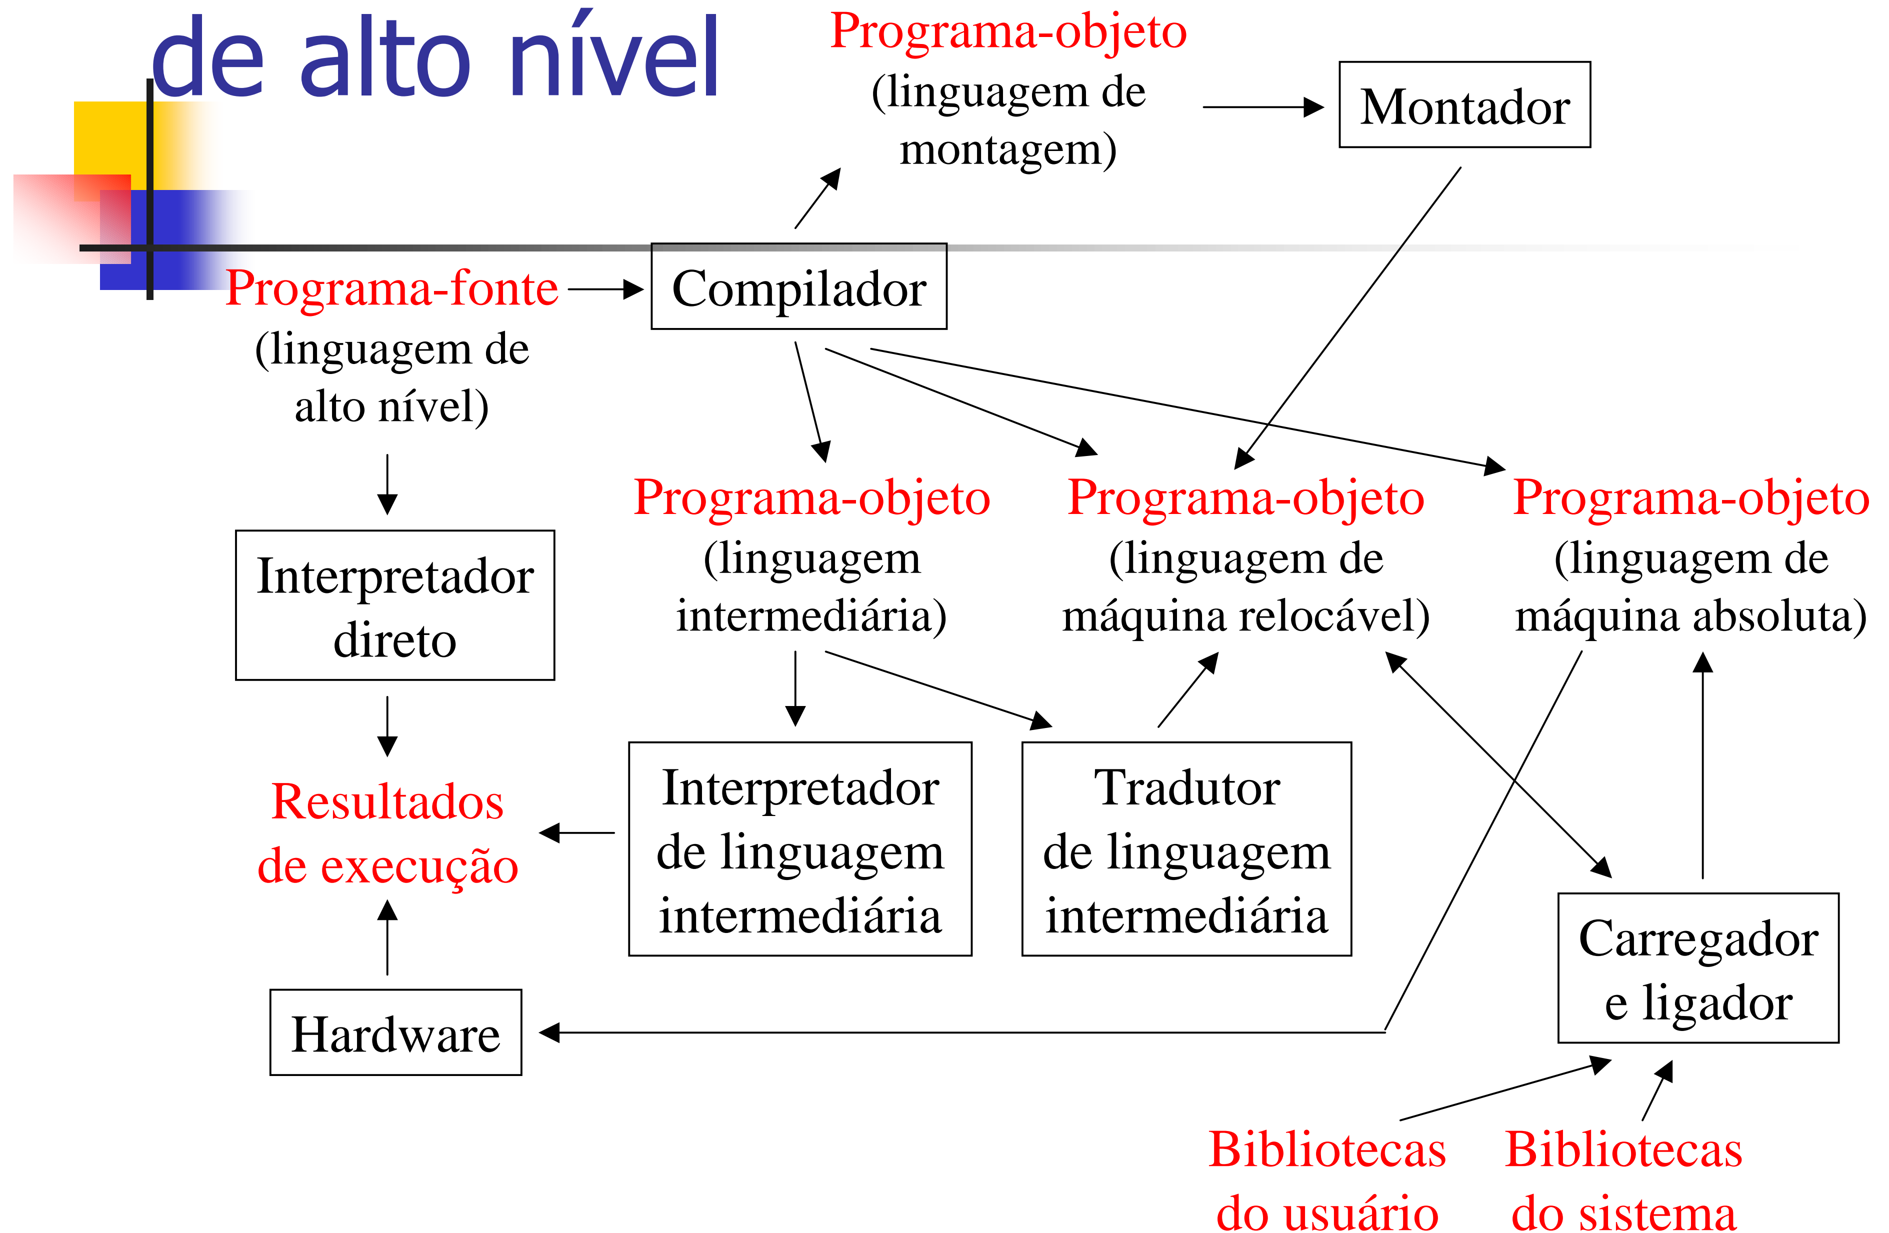

estrutura conceitual de um compilador (1)

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

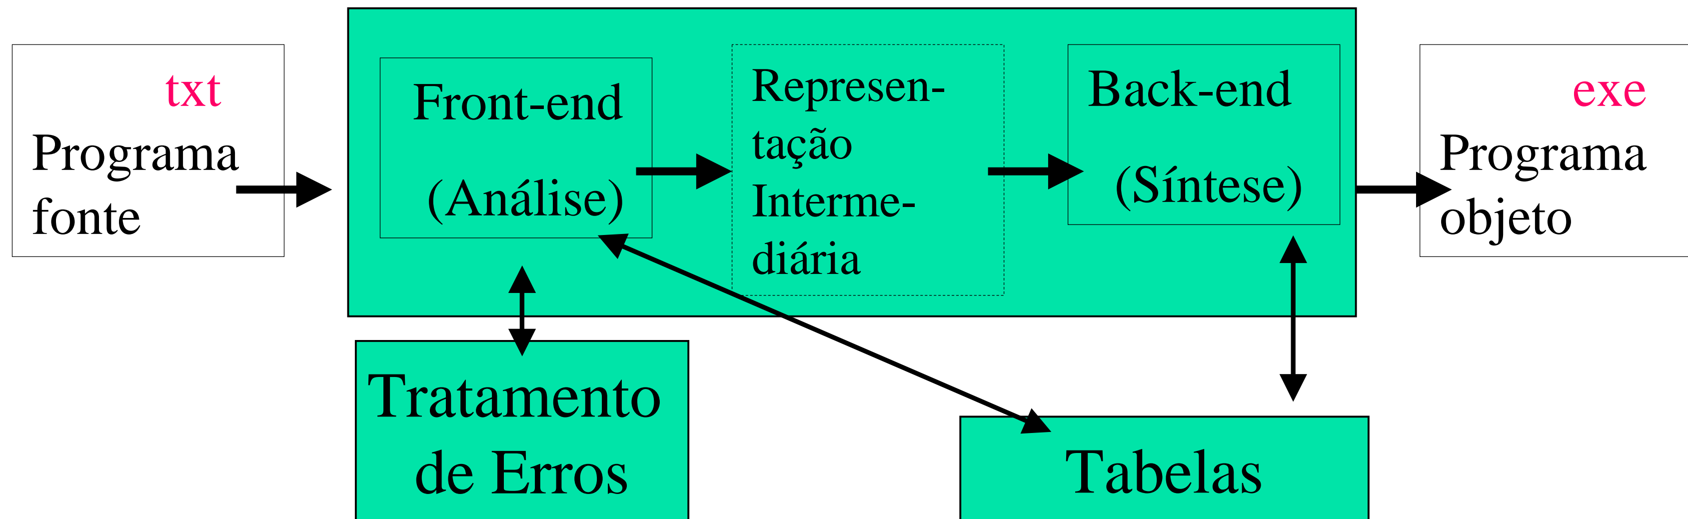

- Fases da Síntese: Otimização Global, Geração de Código, Otimização Local

estrutura conceitual de um compilador (2)

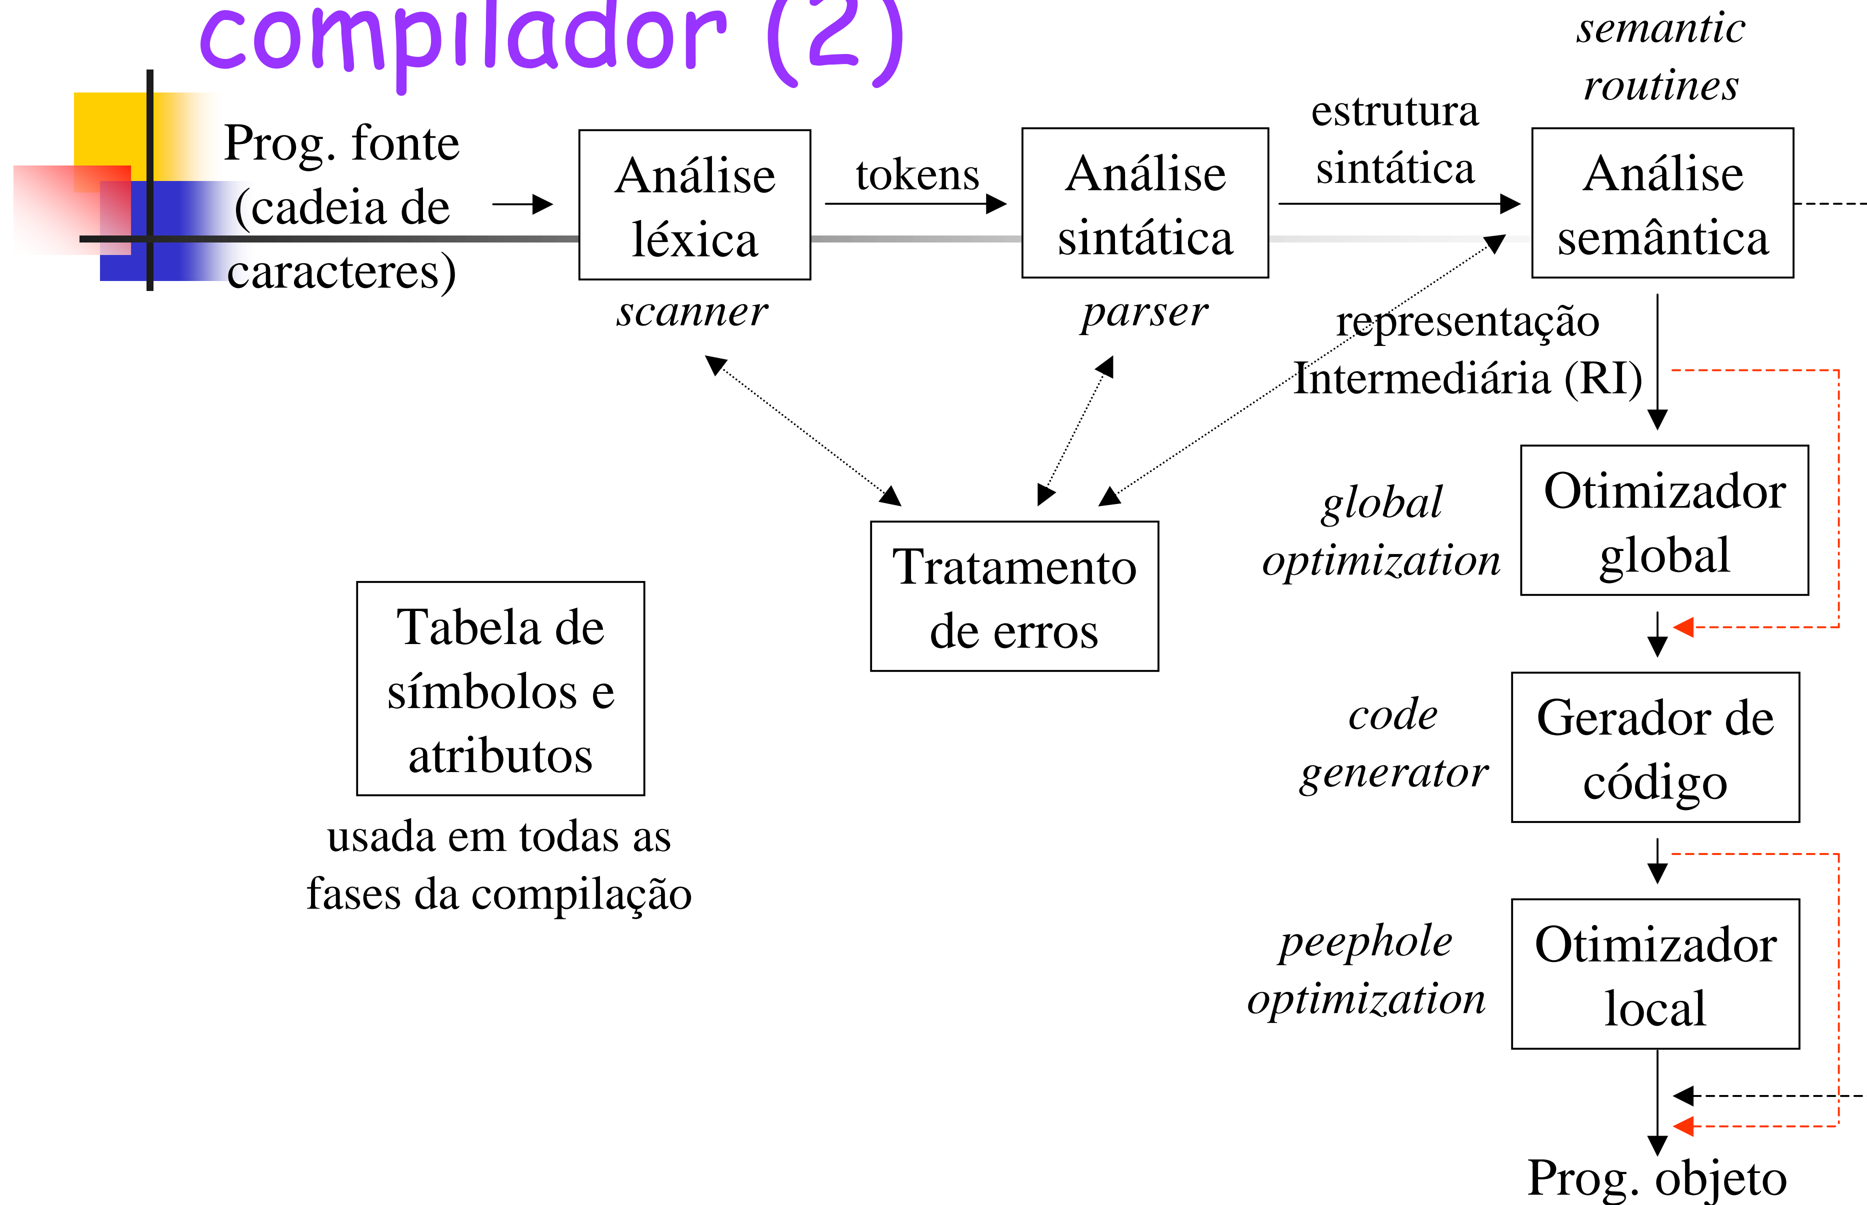

- Análise Léxica: responsável por ler o arquivo em que está armazenado o programa fonte (da esquerda para a direita) e por reconhecer os *tokens* (ou itens léxicos) e lhes dar um rótulo:
    - Palavras reservadas: begin, if, var, ... s_begin, s_if, s_var, ...
    - Identificadores: X, Y, Z, integer,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

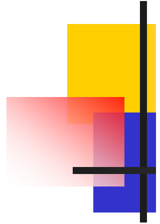

- Análise Sintática: responsável por processar os tokens até reconhecer uma regra sintática que, posteriormente será analisada semanticamente, dado que a gramática é livre de contexto.

    - 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.

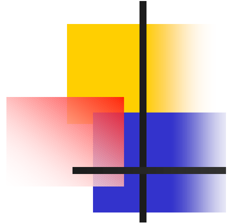

- O. Global: melhorias que, em geral, independem da linguagem de máquina. Por exemplo:
  - eliminação de cálculos repetidos dentro de malhas trazendo-se para fora do loop.
  - Eliminação de sub-expressões iguais:

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.

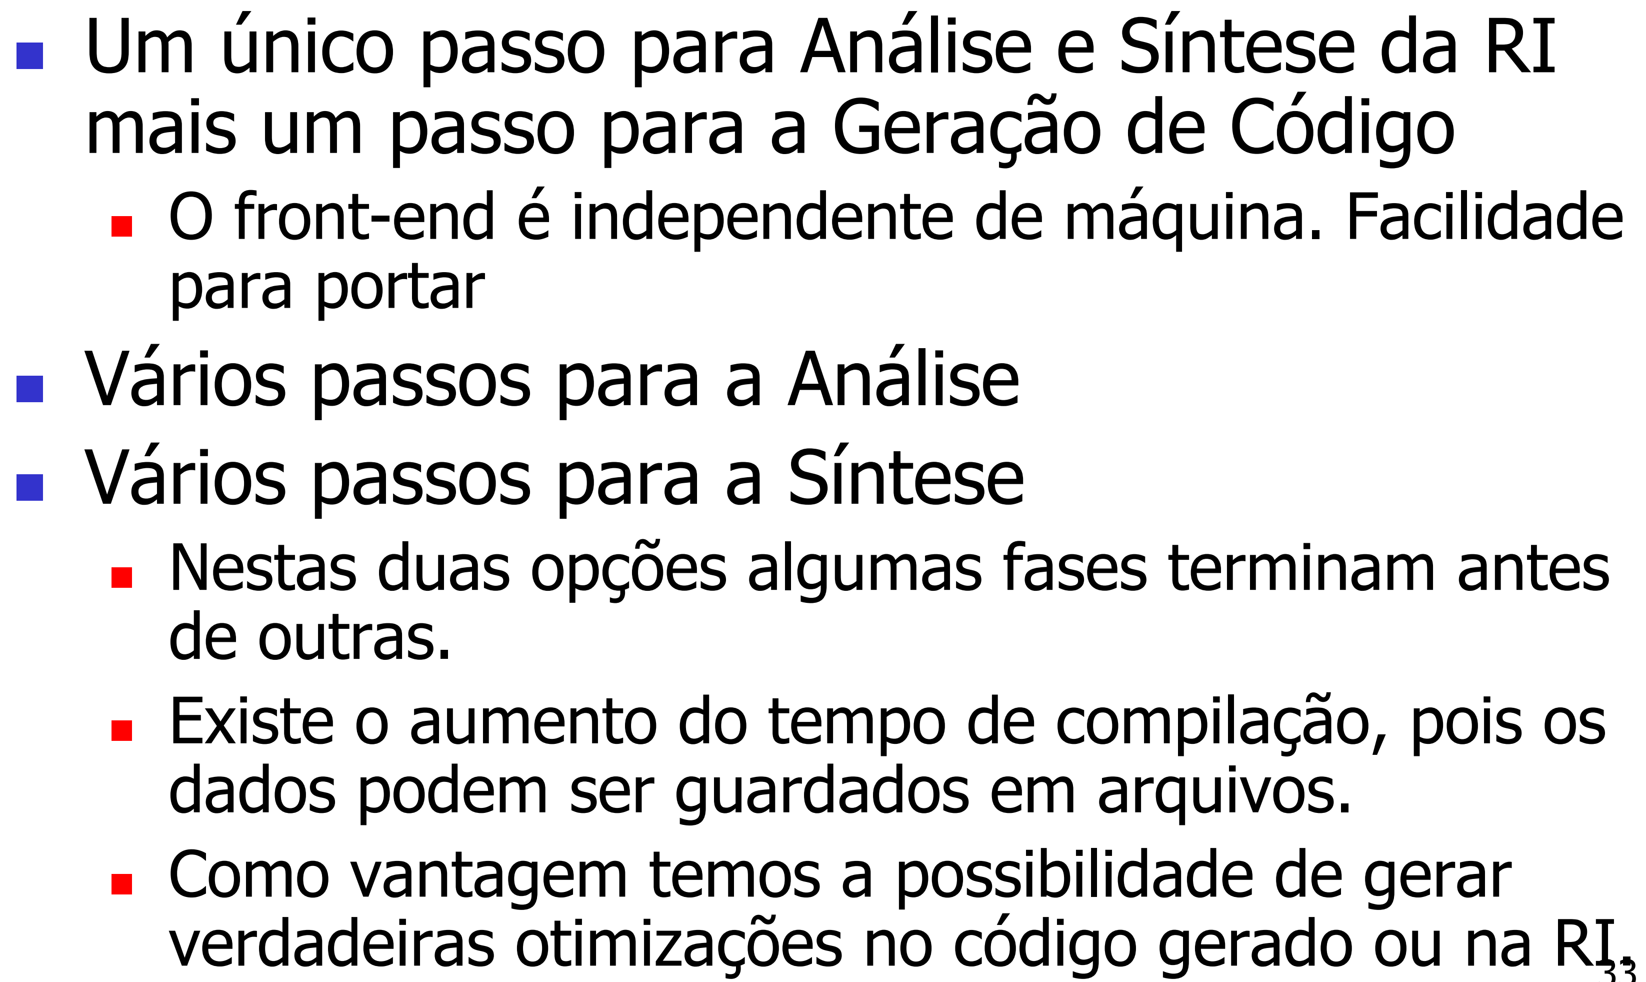

- Um único passo para Análise e Síntese da RI mais um passo para a Geração de Código
  - O front-end é independente de máquina. Facilidade para portar
- Vários passos para a Análise
- Vários passos para a Síntese
  - Nestas duas opções algumas fases terminam antes de outras.
  - Existe o aumento do tempo de compilação, pois os dados podem ser guardados em arquivos.
  - Como vantagem temos a possibilidade de gerar verdadeiras otimizações no código gerado ou na 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) será fornecida oportunamente (será implementada no P3).
- Geração para a linguagem MEPA também será fornecida oportunamente (P4)
- Compilador de um Passo: todas as fases entrelaçadas; compilador dirigido por sintaxe (programa principal).