

Breve Histórico & Conceitos Básicos

compiladores

interpretadores

montadores

filtros

pré-processadores

carregadores

linkers

compilador cruzado (cross-compiler)

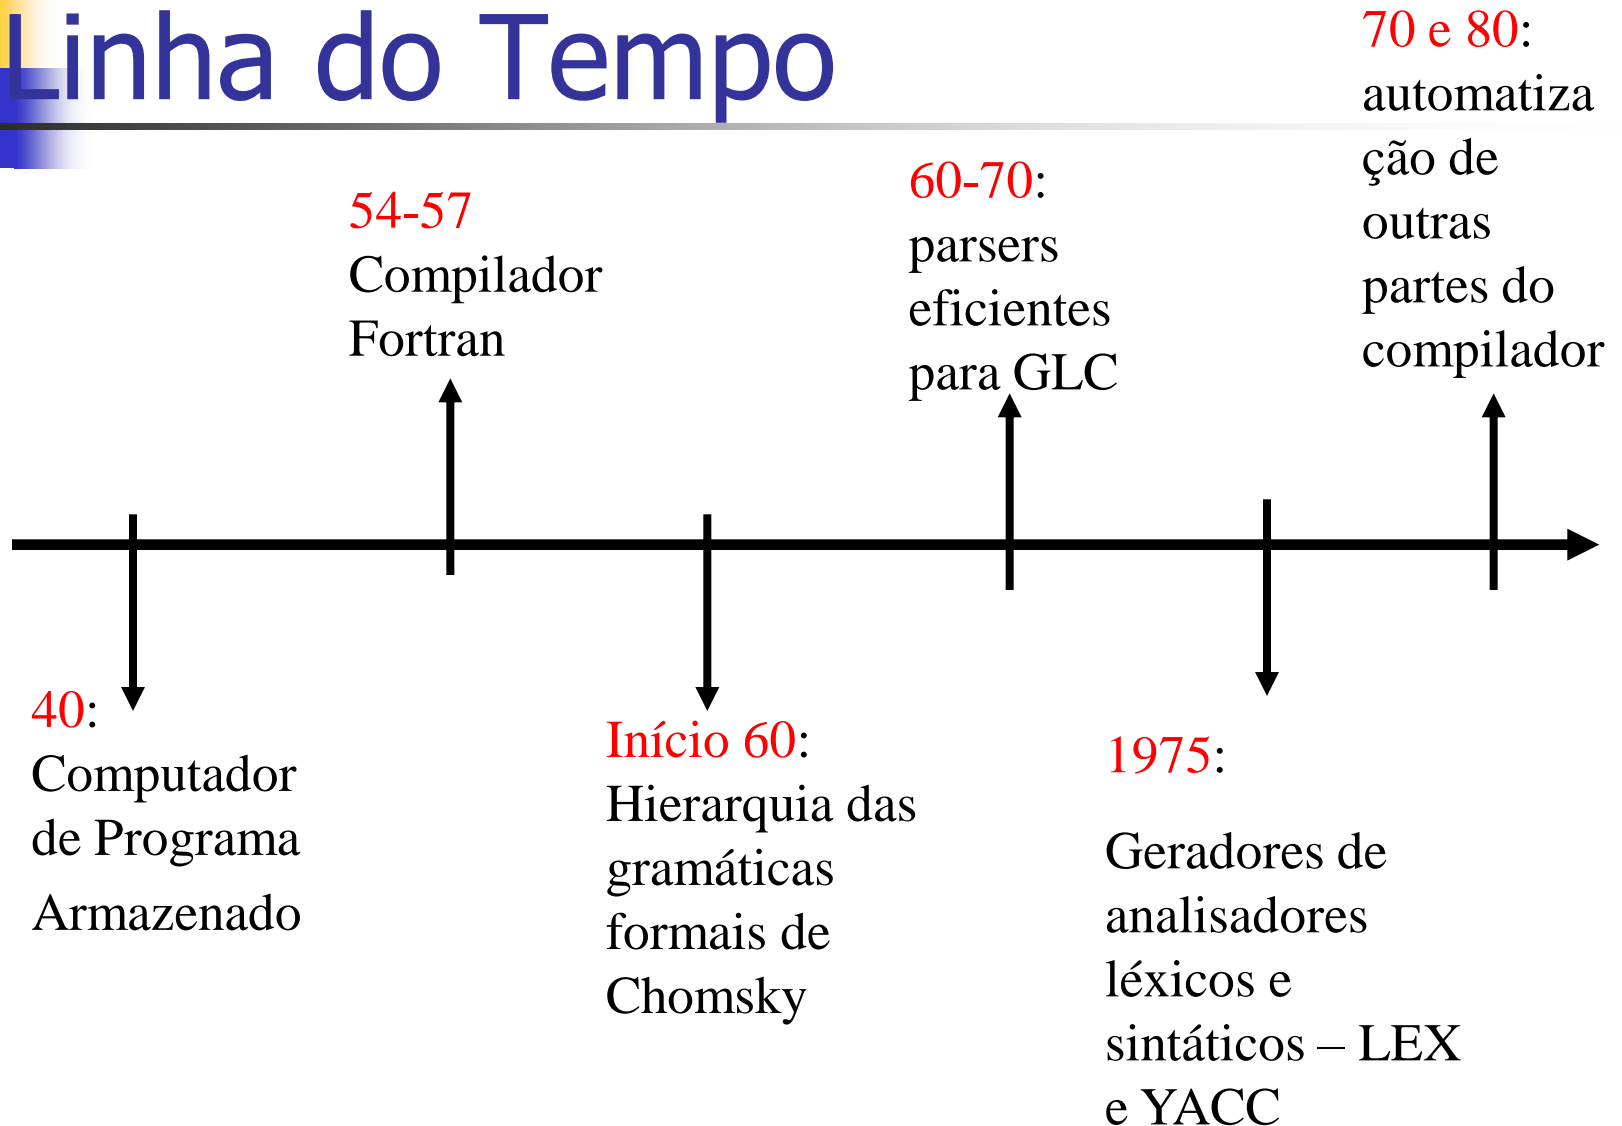
auto-compilável (bootstrapping)

auto-residente

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



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



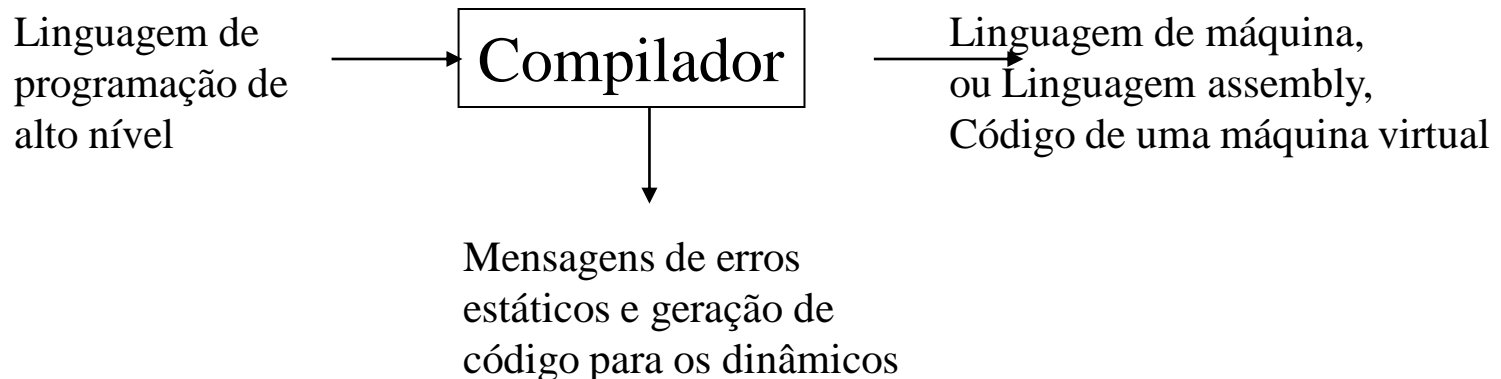
Histórico

- 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)



Linguagem de Alto Nível

- Segundo Price & Toscani (2001) as linguagens de programação podem ser classificadas em **5 gerações**:
 - 1ª linguagens de máquina
 - 2ª linguagens simbólicas (assembly)
 - 3ª linguagens orientadas ao usuário (linguagens procedimentais e declarativas)
 - 4ª linguagens orientadas à aplicação (projetadas para facilitar a programação por usuários finais)
 - 5ª linguagens de conhecimento (usadas na área de IA)
- **As 1ª e 2ª são consideradas de baixo nível e as demais de alto nível.**



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.



Tecnologia de Compiladores

- 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”)


Exemplo: “Pascal P-Compiler” 

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

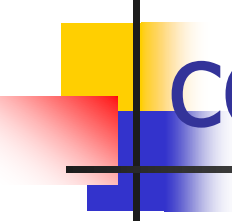
Compiladores também podem ser distinguidos pelo **formato do código objeto** que eles geram:

- **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 (pseudo-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



Linguagem
de montagem

Montador

Linguagem
de máquina

Linguagem de alto nível
(dialeto do Algol)

Filtro

Linguagem de alto nível
muito semelhante à Lf
(Algol 60)

Lf não preparada
(extensões)

Pré-processador

Lf
preparada

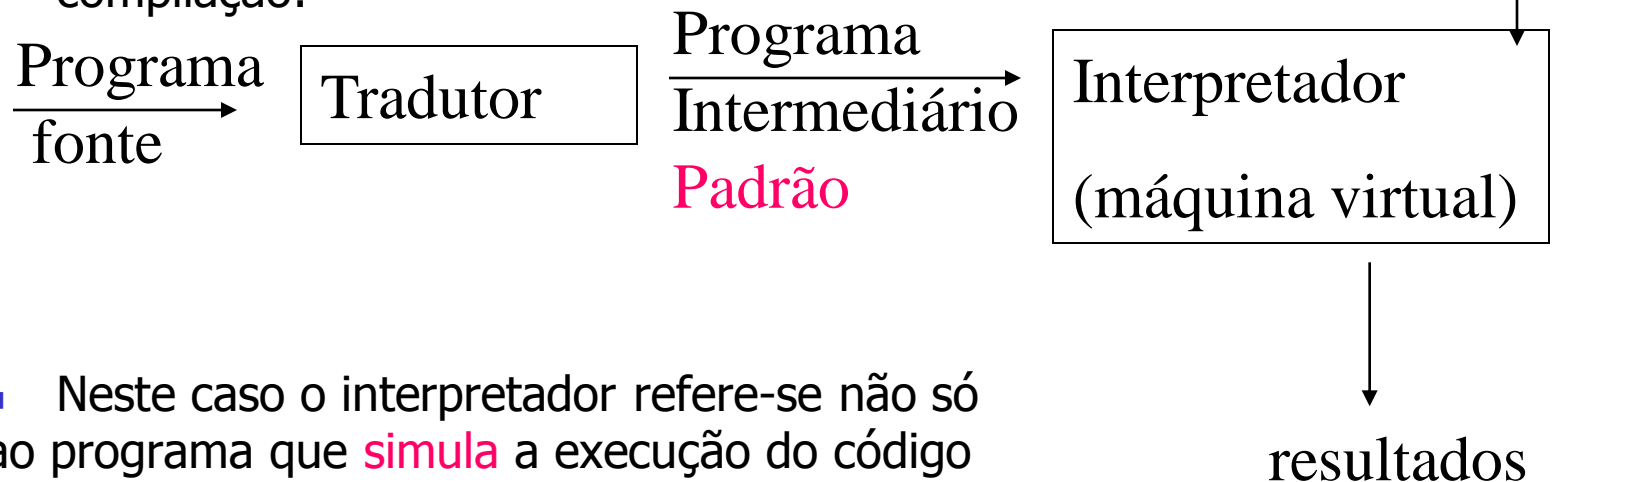
Compilador

Processamento de macros,
inclusão de arquivos

Interpretadores

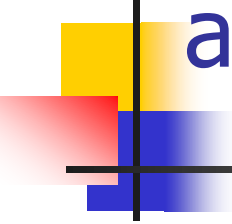
Em vez de traduzir de uma vez o programa-fonte para então executá-lo, decodifica unidades básicas do programa para executá-las imediatamente (não mantém o código-objeto para sempre). Este é um enfoque de interpretação (TRADUZ-EXECUTA), porém consome muito tempo. Ex: BASIC.

- 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


$$C \begin{matrix} \text{LF} & \text{LO} \\ \text{LD} \end{matrix}$$


- 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????



Compilador auto-compilável

- Lisp foi a primeira linguagem a ter um em 1962. C é outra!
- Há vantagens? Facilita o transporte de uma máquina para outra. Suponha que queremos uma linguagem L para as máquinas A e B.
- 1o. Passo: $C \begin{matrix} S & A \\ & A \end{matrix}$ Pode ser escrito numa linguagem aceita por A, assembly, por exemplo

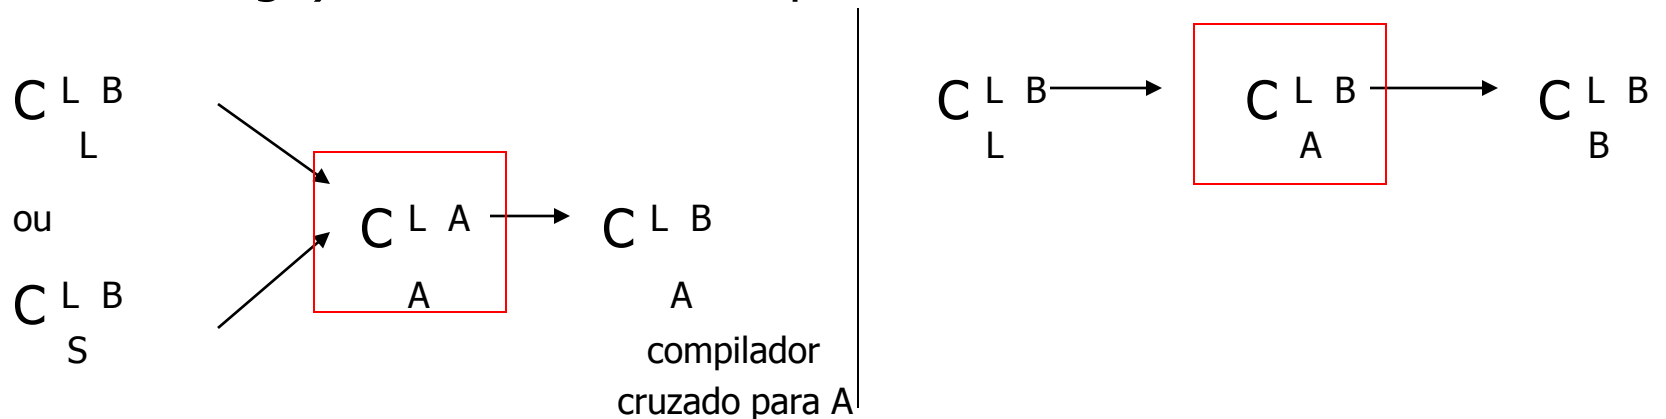
- 2o. Passo: $C^L A$
S



Agora suponha que desejamos ter $C^L B$
B

Como temos $C^L A$ (S) fica mais fácil convertê-lo em $C^L B$ (L)

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)
 - Geradores de analisadores léxicos e sintáticos integrados como o JavaCC
 - Geradores de código (backend generators) como BEG - Code Generator Generation Tool for Creating Portable Compiler(s)

<http://catalog.compilertools.net/>





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 menor 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

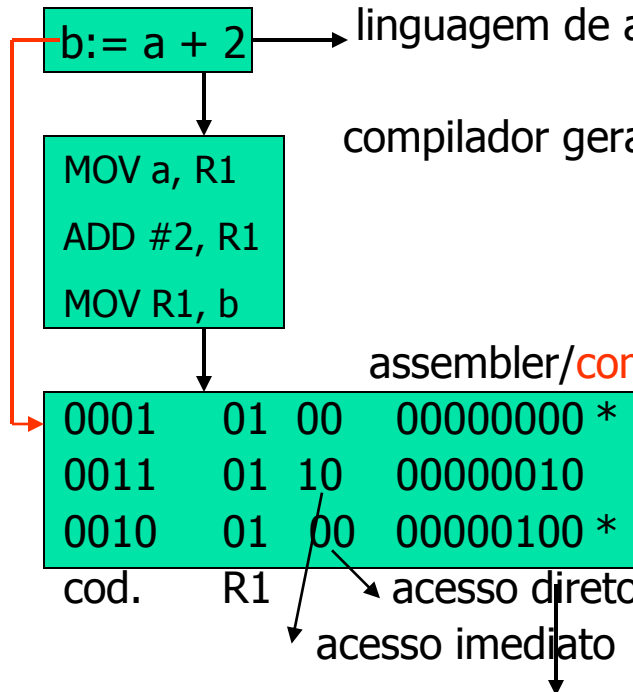
Register Machine

- 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:



linguagem de alto nível

compilador gera código assembly

Pode ser carregado a partir de uma posição L de memória

assembler/compilador gera código de máquina relocável

* 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
0011 01 10 00000010
0010 01 00 00010011
    
```

end. de a (15)
 end. de b (19)

Tabela de símbolos do montador

a	0
b	4

