

Geração de código intermediário

Novembro 2006

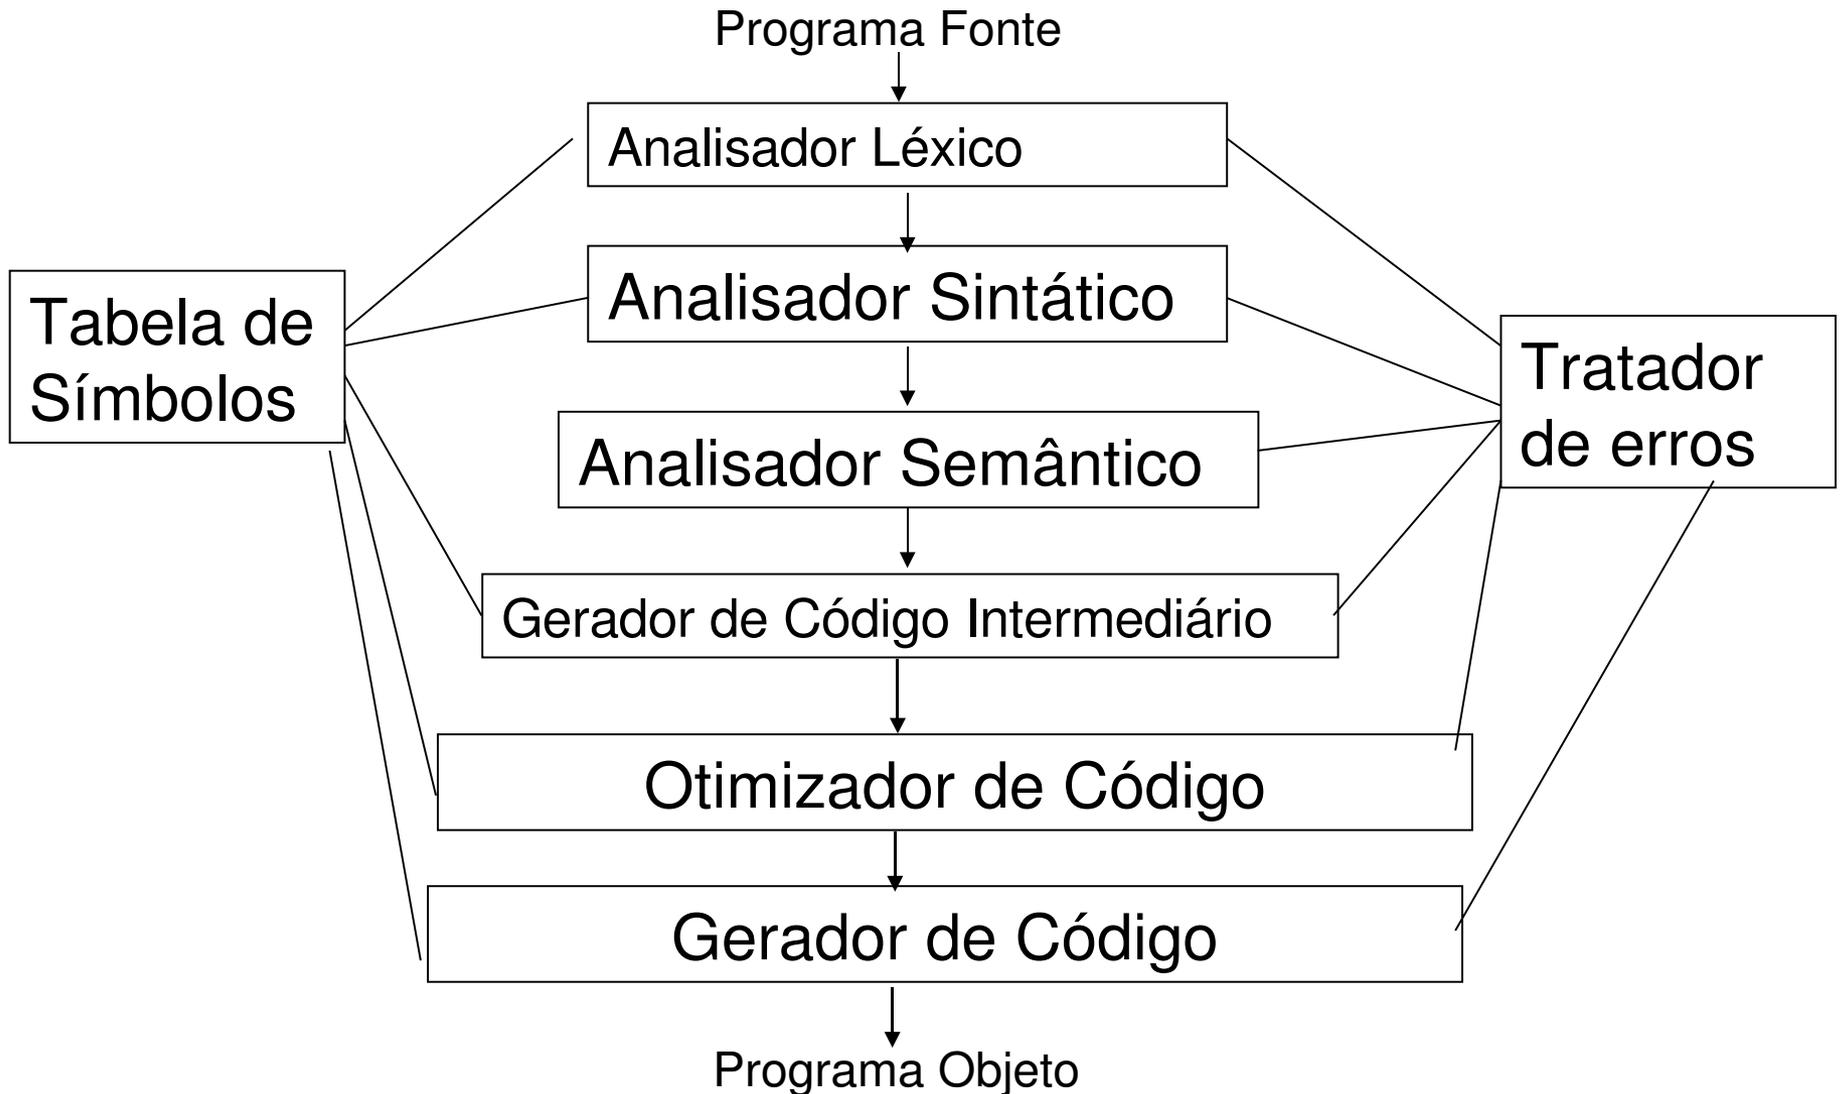
Introdução

- Vamos agora explorar as questões envolvidas na transformação do código fonte em uma possível representação intermediária
- Como vimos, nas ações semânticas já é possível fazer a geração direta de código (assembly por exemplo)

Introdução

- No entanto, a maioria dos compiladores comerciais realizam a geração de uma representação intermediária entre o código fonte e o código de máquina
 - Linguagem intermediária
- Esta representação intermediária é chamada de linguagem intermediária

Fases de um Compilador



Tradução de uma sentença

posicao := inicial + taxa * 60

Analizador Léxico

$id_1 := id_2 + id_3 * 60$

Analizador Sintático

Tabela de Símbolos

1	id_1	position
2	id_2	initial
3	id_3	rate
4		

Tradução de uma sentença



Analisador Sintático

+

Analisador Semântico

+

Gerador de Código Intermediário

Etapas realizadas através de ações semânticas inseridas dentro do analisador sintático

```
temp1 := inttoreal( 60 )
temp2 := id3 * temp1
temp3 := id2 + temp2
id1 := temp3
```

Tradução de uma sentença

Gerador de Código Intermediário



```
temp1 := inttoreal( 60 )
temp2 := id3 * temp1
temp3 := id2 + temp2
id1  := temp3
```



Código de três endereços



Otimizador de Código

Tradução de uma Sentença

```
temp1 := 60.0  
temp2 := id3 * temp1  
temp3 := id2 + temp2  
id1 := temp3
```



```
temp1 := id3 * 60.0  
temp3 := id2 + temp1  
id1 := temp3
```



```
temp1 := id3 * 60  
id1 := id2 + temp1
```



Gerador de Código



Otimizador
de Código

Tradução de uma sentença



temp1 := id₃ * 60

id1 := id₂ + temp1



Gerador de Código



MOVF _taxa, R2

MULF #60.0, R2

MOVF _inicial, R1

ADDF R2, R1

MOVF R1, _posicao

Linguagem Intermediária

- Como observamos, o objetivo de se realizar a geração de código intermediário é permitir a realização de otimizações.
- Qual seria um outro uso de linguagens intermediárias atualmente?
 - Java!

Linguagem Intermediária

- Existe uma variedade de linguagens intermediárias atualmente
- Quando se está projetando um compilador, certamente a decisão de qual linguagem intermediária utilizar é crucial

Linguagem Intermediária

- Dependendo da linguagem intermediária, otimizações de código poderão:
 - ser mais facilmente serem implementadas
 - ser mais difíceis de serem implementadas
 - demandar mais tempo de computação se as linguagens intermediárias forem inapropriadas

Linguagem Intermediária

- Outro ponto importante é observarmos quão independente de máquina a linguagem intermediária é
 - Quanto mais dependente de máquina, será mais difícil de se implementar certas otimizações
- O que muitos compiladores fazem é a utilização de várias representações intermediárias

Linguagem Intermediária

- Durante o processo de compilação, inicialmente gera-se uma primeira representação intermediária, na qual são aplicadas otimizações.
- Em seguida, esta representação otimizada é convertida em outra representação intermediária, conveniente para a aplicação de outras otimizações

Linguagem Intermediária

- Um exemplo de compilador que realiza tal estratégia é o compilador da Hewlett-Packard para PA-RISC
- As linguagens intermediárias podem ser classificadas em:
 - Linguagens intermediárias de alto nível
 - Próximas da linguagem fonte
 - Linguagens intermediárias de nível médio
 - Linguagens intermediárias de baixo nível
 - Próximas da linguagem alvo

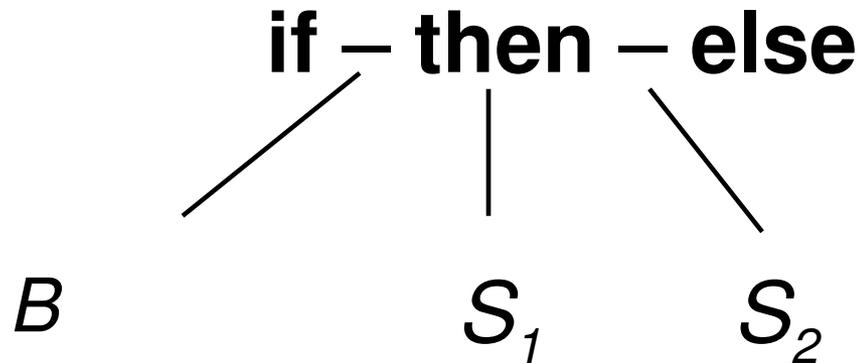
Linguagem Intermediária

- Um compilador pode gerar mais de uma destas representações durante o processo de compilação
- Uma possível forma de representação intermediária é a árvore sintática

Árvores Sintáticas

- Uma **árvore sintática** é uma forma condensada de árvore gramatical, útil para a representação das construções de linguagem
- A produção $S ::= \text{if } B \text{ then } S_1 \text{ else } S_2$ poderia aparecer numa árvore sintática como:

Árvores Sintáticas



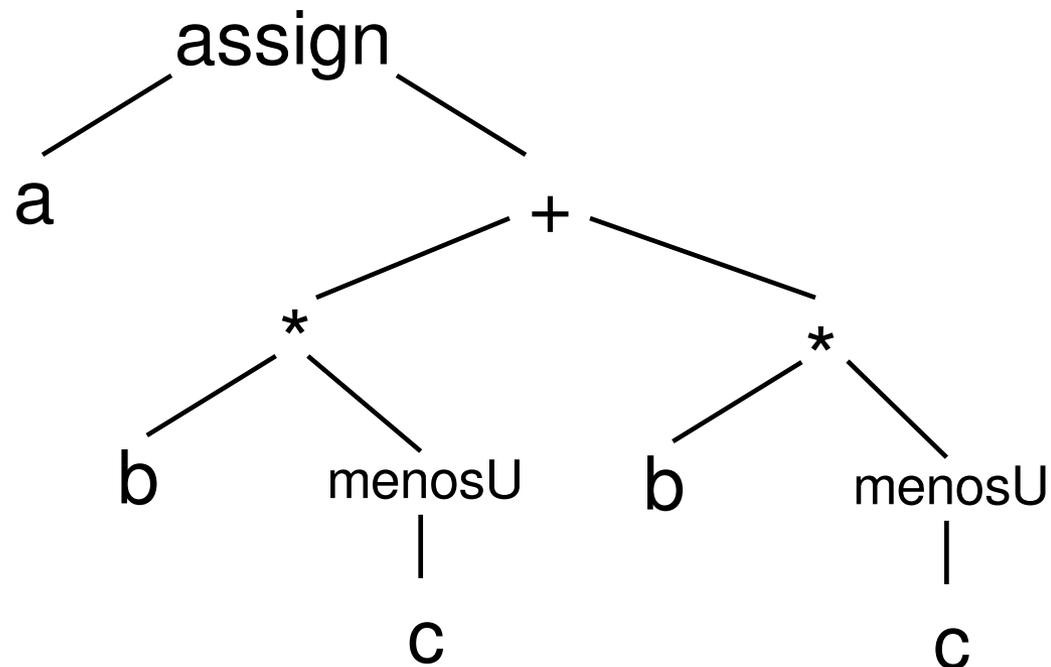
- Numa árvore sintática os operadores e as palavras chaves não figuram como folhas, ao contrário, são associados a um nó interior

Árvores Sintáticas

- Exemplo: Para a expressão

$a := b * -c + b * -c$

teremos a seguinte árvore sintática



Árvores Sintáticas

- Árvores sintáticas permitem que a geração de código seja desacoplada da análise sintática
- A geração das árvores sintáticas é feita através de ações semânticas
- Exemplo: para um comando de atribuição poderíamos ter a gramática com as seguintes ações semânticas:

Árvores Sintáticas

Regra Semântica

$S \rightarrow \mathbf{id} := E$

$S.nptr := \text{criar_no}(\text{'assign'},$
 $\text{criar_folha}(\mathbf{id}, \mathbf{id.local}), E.nptr)$

$E \rightarrow E_1 + E_2 \mid$

$E.nptr := \text{criar_nó}(\text{'+'}, E_1.nptr, E_2.nptr)$

$E_1 * E_2 \mid$

$E.nptr := \text{criar_nó}(\text{'*'}, E_1.nptr, E_2.nptr)$

$-E_1 \mid$

$E.nptr := \text{criar_nó}(\text{'menosU'}, E_1.nptr)$

$(E_1) \mid$

$E.nptr := E_1.nptr$

\mathbf{id}

$E.nptr := \text{criar_folha}(\mathbf{id}, \mathbf{id.local})$

Grafos Dirigidos Acíclicos

- Um Grafo Dirigido Acíclico GDA também é uma representação intermediária de um compilador
 - Um (GDA) para uma expressão identifica as subexpressões comuns existentes na mesma
 - Como uma árvore sintática, um GDA possui um nó para cada subexpressão de uma expressão
 - Um nó interior representa um operador e os filhos representam seus operandos

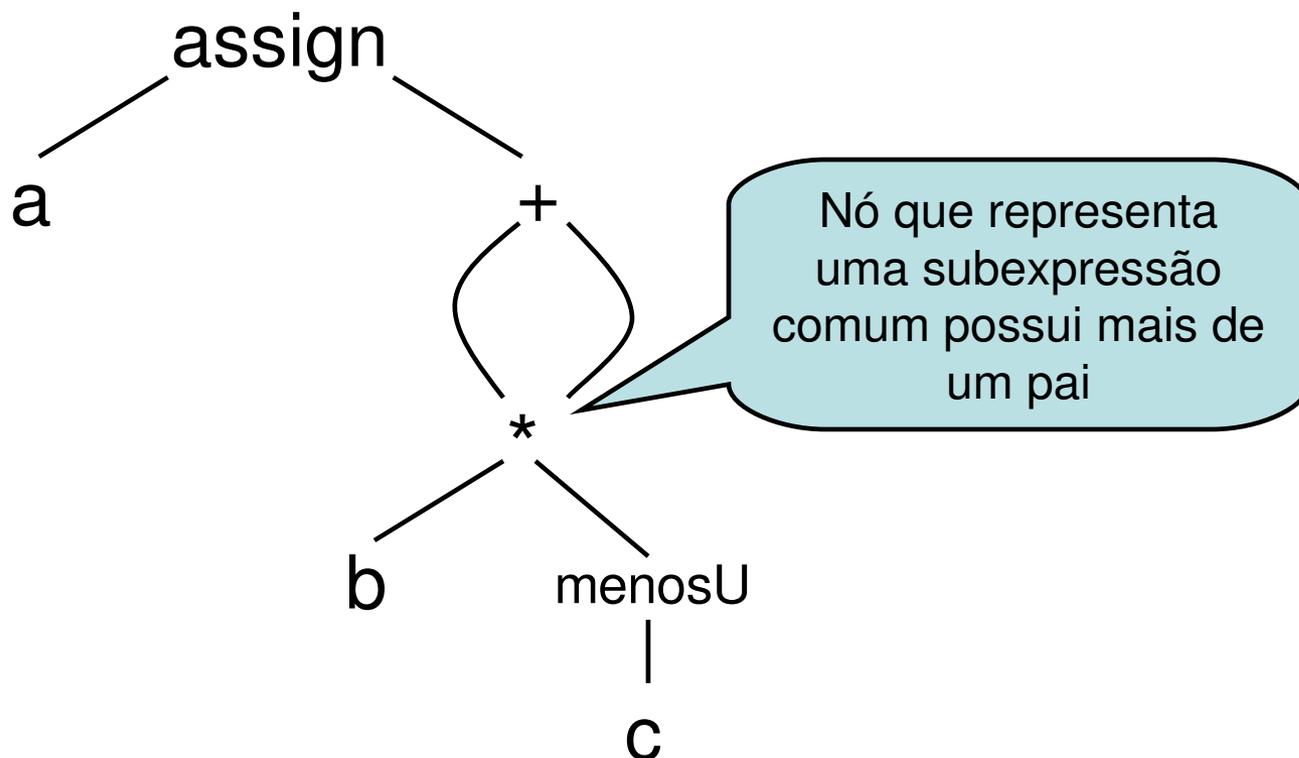
Grafos Dirigidos Acíclicos

- A diferença entre um GDA e uma árvore sintática (AS) é que, um nó de um GDA representando uma subexpressão comum, possui mais de um pai
 - O GDA fornece as mesmas informações da AS, porém de maneira mais compacta
- Logo, no exemplo visto anteriormente teríamos:

Grafos Dirigidos Acíclicos

- Exemplo: Para a expressão

$a := b * -c + b*-c$ teremos o GDA



Grafos Dirigidos Acíclicos

- As regras semânticas podem criar os GDA's
- As mesmas regras vistas anteriormente poderiam ser usadas
- A função `criar_nó` (`op`, `esquerdo`, `direito`) deverá verificar, antes de criar um novo nó, se já não existe um nó com raiz *op* e filhos *direito* e *esquerdo*

Grafos Dirigidos Acíclicos

- Exercício

Monte o GDA para a seguinte expressão:

$$(a + b) * a + a + (a + b) * c$$

Código de Três endereços

- É composto por uma seqüência de instruções envolvendo operações binárias ou unárias e uma atribuição
 - O nome ‘três endereços’ está associado à especificação, em uma instrução, de no máximo três operandos: dois para os operadores binários e uma para o resultado
- Ex: $t1 = -c$
 $t2 := b * t1$
 $c := t2$

Código de Três Endereços

- O código de três endereços é uma seqüência de enunciados da forma geral
$$x := y \text{ op } z$$
- Onde, x , y e z são nomes, constantes ou objetos de dados temporários criados pelo compilador
- op está no lugar de qualquer operador

Código de Três Endereços

- Assim, expressões envolvendo diversas operações são decompostas nesse código em uma série de instruções, eventualmente com a utilização de variáveis temporárias introduzidas na tradução.
 - Dessa forma, obtém-se um código mais próximo da estrutura da linguagem *assembly*

Código de Três Endereços

- No código de três endereços não são permitidas expressões aritméticas construídas, já que só há um operador
- Logo, uma expressão da forma $x + y * z$ poderia ser traduzida na seqüência

$$t_1 := y * z$$

$$t_2 := x + t_1$$

- Os temporários são construídos para os nós interiores da árvore sintática

Código de Três Endereços

- Os enunciados de três endereços são semelhantes ao código de montagem (linguagem assembly)

Código de Três Endereços

- Uma possível especificação de uma linguagem de três endereços envolve quatro tipos básicos de instruções:
 - Expressões com atribuição
 - Acesso indexado e indireto
 - Desvios
 - Invocação de rotinas

Instruções de atribuição

- São aquelas nas quais o resultado de uma operação é armazenado na variável especificada à esquerda do operador de atribuição, aqui denotado por $:=$
- Há três formas para esse tipo de instrução:
 - Na primeira, a variável recebe o resultado de uma operação binária
 $x := y \text{ op } z$

Instruções de atribuição

- Na segunda, o resultado pode ser obtido a partir da aplicação de um operador unário:

$x := \text{op } y;$

- Na terceira forma, pode ocorrer uma simples cópia de valores de uma variável para outra:

$x := y$

Instruções de atribuição - Exemplo

- Por exemplo, a instrução em linguagem de alto nível:

$a = b + c * d;$

seria traduzida nesse formato para as instruções:

$_t1 := c * d$

$a := b + _t1$

Acesso Indexado e Indireto

- Para atribuições indexadas, as duas formas básicas são

$x := y[i]$

$x[i] := y$

- A forma $x := y[i]$ atribui à x o valor armazenado i posições de memória a partir do endereço de memória y
- A forma $x[i] := y$ atribui o valor y à posição de memória com deslocamento i partir do endereço de memória x

Instruções de Desvio

- As **instruções de desvio** podem assumir duas formas básicas.
- Uma instrução de desvio incondicional tem o formato:

goto L

onde L é um rótulo simbólico que identifica uma linha do código.

Instruções de Desvio

- A outra forma de desvio é o desvio condicional, com o formato:

if x opr y goto L

onde:

- opr é um operador relacional de comparação (<, <=, ... etc)
- L é o rótulo da linha que deve ser executada se o resultado da aplicação do operador relacional for verdadeiro;
- caso contrário, a linha seguinte é executada.

Instruções de Desvio

- Por exemplo, a seguinte iteração em C
while (i++ <= k)
 x[i] = 0;
x[0] = 0;

Instruções de Desvio

Poderia ser traduzida em:

```
_L1: if i > k goto _L2
```

```
    i := i + 1
```

```
    x[i] := 0
```

```
    goto _L1
```

```
_L2: x[0] := 0
```

Otimização de Código

- Várias são as otimizações realizadas por um compilador:
 - Alocação de registradores: Tenta evitar a gravação/leitura de valores de/para a memória principal fazendo que os mesmos residam em registradores
 - Propagação de constantes: Propaga sempre que possível constantes em expressões

Invocação de rotinas

- A **invocação de rotinas** ocorre em duas etapas:
 - Inicialmente, os argumentos do procedimento são ‘registrados’ com a instrução param.
 - Após a definição dos argumentos, a instrução call completa a invocação da rotina

Invocação de rotinas

- A instrução return indica o fim de execução de uma rotina.
 - Opcionalmente, esta instrução pode especificar um valor de retorno, que pode ser atribuído na linguagem intermediária a uma variável como resultado de call

Invocação de rotina - Exemplo

- Por exemplo, considere a chamada de uma função f que recebe três argumentos e retorna um valor:

$f(a, b, c);$

Invocação de rotina - Exemplo

- Neste exemplo em C, esse valor de retorno não é utilizado. De qualquer modo, a expressão acima seria traduzida para

param a

param b

param c

_t1 := call f,3

Invocação de rotina - Exemplo

- Onde o número após a vírgula indica o número de argumentos utilizados pelo procedimento f.
- Com o uso desse argumento adicional é possível expressar sem dificuldades as chamadas aninhadas de procedimentos.

Atribuições de ponteiro e endereço

- As instruções em formato intermediário também utilizam um formato próximo àquele da linguagem C:

$x := \&y$

$w := *x$

$*x := z$

Implementação de código de Três Endereços

- A representação interna das instruções em códigos de três endereços dá-se na forma de armazenamento em:
 - Tabelas com quatro colunas (quadrúplas)
 - Tabelas com três colunas (triplas)

Quádruplas

- Na abordagem que utiliza **quádruplas**, cada instrução é representada por uma linha na tabela com a especificação do:
 - Operador
 - Primeiro argumento
 - Segundo argumento
 - e do resultado.

Quádruplas

- Por exemplo, a tradução da expressão $a = b + c * d;$ resultaria no seguinte trecho da tabela:

	operador	arg ₁	arg ₂	resultado
1	*	c	d	_t1
2	+	b	_t1	a

Quádruplas

- Para algumas instruções, como aquelas envolvendo operadores unários ou desvio incondicional, algumas das colunas estariam vazias.

Triplas

- Na outra forma de representação, por **triplas**, evita-se a necessidade de manter nomes de variáveis temporárias ao fazer referência às linhas da própria tabela no lugar dos argumentos.

	operador	arg ₁	arg ₂	resultado
1	*	c	d	_t1
2	+	b	_t1	a



Triplas

- Nesse caso, apenas três colunas são necessárias, uma vez que o resultado está sempre implicitamente associado à linha da tabela.

Triplas

- No mesmo exemplo apresentado para a representação interna por quádruplas, a representação por triplas seria:

	operador	arg ₁	arg ₂
1	*	c	d
2	+	b	(1)