

Gerador de código para Compilador Pascal

Este exemplar corresponde à redação da tese defendida  
Akira Oyama  
pelo Sr. Akira Oyama e aprovada pela Comissão Julgadora.



Orientador: Prof. Dr. Celio Sardoso Guimaraes

Dissertação apresentada ao Instituto de  
Matemática, Estatística e Ciência da  
Computação como requisito parcial para a  
obtenção do título de Mestre em Ciência da  
Computação.

Agosto - 1984

**UNICAMP**  
**BIBLIOTECA CENTRAL**

#### AGRACIAMENTOS

Ao Prof. Celio Cardoso Guimaraes pelo trabalho de orientacao.

Aos colegas e amigos que direta ou indiretamente contribuiram para a realizacao deste trabalho.

A Solange que apoiou o meu estudo com bastante sacrificio e paciencia.

'A minha filhinha Mayara...'

## SUMMARY

We present in this thesis a code generator for a Pascal Compiler. The code generator was written as the second pass of an existent Pascal Compiler, Pascal NBS for PDP 11. The target machine is the INTEL 8088 microprocessor. Our objective is to obtain an efficient code generator in terms of memory.

The results shown in the chapter 6 demonstrate that our objective was reasonably achieved.

## RESUMO

O trabalho aqui apresentado é um gerador de código para um Compilador Pascal. O gerador de código foi escrito como o segundo passo de um compilador Pascal existente, o compilador NBS para o PDP 11. A máquina objeto é o microprocessador 8088 da INTEL. O nosso objetivo foi obter um gerador de código eficiente em termos de memória.

Os resultados descritos no capítulo 6 mostram que o nosso objetivo foi razoavelmente atingido.

## GERADOR DE CODIGO PARA COMPILADOR PASCAL

### SUMÁRIO

CAPÍTULO 1	INTRODUÇÃO
1.1	OBJETIVO DA TESE
1.2	HISTÓRIA DO COMPILADOR PASCAL NBS
1.3	ESQUEMA GERAL DO PROJETO
CAPÍTULO 2	DESCRICAÇÃO DO PASCAL NBS
2.1	A LINGUAGEM PASCAL
2.2	DIFERENÇAS ENTRE PASCAL NBS E ORIGINAL
CAPÍTULO 3	DESCRICAÇÃO DO CODIGO-P
3.1	CODIGO-P E ÁRVORE DE SINTAXE
3.2	IMPLEMENTAÇÃO DE CODIGO-P NO PASCAL NBS
CAPÍTULO 4	ADAPTAÇÃO DO COMPILADOR PARA A MÁQUINA
4.1	CARACTERÍSTICAS DO INTEL 8088
4.2	ALOCAÇÃO DE REGISTRADORES
4.3	ENDEREÇAMENTO E ALOCACAO DE MEMÓRIA
4.4	MAPA DE MEMÓRIA
4.5	ROTINAS DE SUPORTE DURANTE EXECUÇÃO
CAPÍTULO 5	OTIMIZAÇÃO E GERAÇÃO DE CODIGO
5.1	EXPRESSÕES
5.2	ENDERECOS
5.3	O PROBLEMA DE SALTO NO INTEL 8088
5.4	OTIMIZAÇÕES MISCELANEAS
5.5	OTIMIZAÇÃO "PEEPHOLE"
5.6	ATRIBUIÇÃO
5.7	COMANDO "IF"
5.8	COMANDO "CASE"
5.9	COMANDO "WHILE", "REPEAT" E "LOOP"
5.10	COMANDO "FOR"
5.11	COMANDO "WITH"
5.12	INTERFACE DE SUBROTINAS
CAPÍTULO 6	TESTES DO COMPILADOR
6.1	CONFIDABILIDADE DO CODIGO GERADO
6.2	TAMANHO DO CODIGO GERADO
6.3	TEMPO DE EXECUÇÃO DO CODIGO GERADO

CAPÍTULO 7 PROSPECTIVAS DO PROJETO

APÊNDICE A TABELA DE CÓDIGO-P

APÊNDICE B LISTA DE ROTINAS INTRÍNSECAS

APÊNDICE C TABELA DE OPÇÕES DE COMPILAÇÃO

APÊNDICE D BIBLIOGRAFIA

## CAPITULO 1

### INTRODUCAO

#### 1.1 OBJETIVO DA TESE

O objetivo principal da tese foi desenvolver um eficiente gerador de código para um compilador Pascal. O objetivo a longo prazo é desenvolver um compilador Pascal "residente" num sistema baseado em microprocessador de 16 bits. O microprocessador escolhido para este projeto foi o INTEL 8088. Vários objetivos foram perseguidos neste projeto.

1. O tamanho do código do compilador deve ser razoavelmente pequeno. Para o compilador ser residente, o código do compilador deve ser compacto. O objetivo deste projeto nesse aspecto é conseguir um compilador Pascal de dois passos que se auto-compila em cerca de 64 K bytes de memória.
2. O compilador deve gerar código eficiente e compacto. Esta condição é relacionada à condição citada acima, pois o compilador é auto-compilável.
3. O compilador deve implementar quase todos os recursos definidos no Pascal por Niklaus Wirth. (Chamaremos de Pascal original, no que se segue, o Pascal definido por Niklaus Wirth no "Revised Report" [Wirt76].) Esta condição tem uma relação de compromisso com a condição (1). A linguagem Pascal-S definida por Niklaus Wirth, por exemplo, é um subconjunto do Pascal. Pascal-S possui apenas 20 por cento a menos das construções do Pascal original e, em consequência desta simplificação, consegue 70 % de redução na complexidade de implementação [Wilts79].)

4. A execucao do codigo gerado pelo compilador deve ser rapida. A primeira implementacao do Pascal em micro processador de 8 bits foi o compilador de San Diego, para o INTEL 8080. O codigo gerado por este compilador e' interpretado, e isto substancialmente diminui a velocidade de execucao. Esta condicao esta' relacionada com a condicao (2).
5. O compilador deveria ser desenvolvido em tempo relativamente curto.
6. O codigo gerado deve ser confiavel

Considerando estas condicoes, resolvemos adaptar um compilador ja' existente (compilador Pascal NBS), ao inves de desenvolver um original. O compilador Pascal NBS(National Bureau of Standards) foi desenvolvido por Brian G. Lucas e Justin C. Walker para o National Bureau of Standards, o que de agora por diante chamaremos de compilador Pascal NBS.

## 1.2 DESCRICAO GERAL DO COMPILEADOR PASCAL NBS

O compilador Pascal NBS se destina ao minicomputador PDP 11 sob os sistemas UNIX, RSX11-D, RSX11-M, e RT-11 e apresenta duas caracteristicas muito importantes para o projeto:

1. É feito em dois passos independentes;

### 1. Passo 1

Faz a analise sintatica descendente recursiva e gera código intermediário denominado código-P. A ideia básica do código-P foi derivada do "P-compiler" desenvolvido por Urs Amann [Aman78].

O código intermediário é gerado em arquivos temporários. Este código é quase independente da máquina.

### 2. Passo 2

A partir do código intermediário, constroi a árvore de sintaxe de cada procedimento e gera código de máquina para o PDP 11, com algumas otimizações locais.

O compilador NBS requer aproximadamente 59 K bytes de memória para o Passo 1 e 62 K bytes para o Passo 2, para auto-compilação no PDP 11.

2. É auto compilável no PDP 11. Os dois passos são escritos em Pascal NBS, exceto a biblioteca de suporte em tempo de execução. Ele é capaz de auto-compilar-se em cerca de cinco minutos de CPU do PDP-11/45.

### 1.3 ESQUEMA GERAL DO TRABALHO

O projeto foi desenvolvido com duas ferramentas físicas principais:

1. Computador DEC 10 com Pascal de Hamburgo, Montador e Ligador cruzado para o INTEL 8088.
2. Sistema de desenvolvimento do INTEL 8088 do laboratorio de Microprocessadores do centro de computacao(CUECC) e instituto de matematica(IMECC) da UNICAMP. Atualmente o sistema possui 32K bytes de memoria RAM e esta' ligado ao DEC 10 atraves de uma linha serial de 1200 bauds. Um carregador especial permite a carga atraves da linha serial de codigo objeto montado no DEC 10(DOWN LINE LOADING). O microcomputador possui recursos simples para depuracao de programas.

O passo 1 do Compilador Pascal NBS foi modificado para funcionar no PDP-10 com o compilador Pascal de Hamburgo. O Passo 2 do compilador original foi dispensado inteiramente e decidimos desenvolver um outro Passo 2, pelas seguintes razoes:

1. O Passo 2 original e' bastante complicado e as arquiteturas do PDP 11 e INTEL 8088 sao bem diferentes.
2. Como entendemos o funcionamento do Passo 1 muito bem, tinnamos condicao de desenvolver o Passo 2 original.

O passo 2 gera codigo em linguagem de montagem e codigo da maquina. Apenas o codigo em linguagem de montagem foi testado.

A adaptacao do Passo 1 para o sistema DEC 10 foi bastante trabalhosa. Alem disso, a falta de acesso ao PDP 11, dificultou o entendimento do Compilador. As conclusoes citadas posteriormente mostram que conseguimos desenvolver gerador de codigo equivalente, em eficiencia de memoria, ao original.

#### 1.4 MODIFICACOES E ADICAOES NO COMPILEADOR NBS

Foram feitas algumas modificações no Compilador:

1. Adição de verificação em tempo de execução de:
  1. Disponibilidade de memória na alocação dinâmica e estática
  2. Limites de índices de vetores
  3. Overflow e Underflow em operações aritméticas
  4. Validade de referência à área de memória HEAP
  5. Validade de valor de seletor num comando CASE
2. Adição de comando HALT e seletor OTHERS no comando CASE. Na execução do comando HALT, o sistema para a execução e informa o número da linha do programa fonte em que este comando foi executado. A partir deste ponto, podemos também continuar a execução com um comando do sistema MONITOR do INTEL 8088.
3. A interface de sistema de execução foi modificada. O compilador original usa uma cadeia estática e uma cadeia dinâmica. A cadeia estática não é utilizada porque a passagem de função com parâmetros foi excluída no Pascal NBS. Um vetor de display é guardado na memória. O acesso à uma variável global do programa é feito com endereçamento direto. Para aumentar a eficiência do código gerado, utilizamos o registrador BP como apontador do nível da rotina corrente na pilha. O acesso a uma variável ou parâmetro de nível lexical intermediário é feita indiretamente através de vetor de DISPLAY na memória.

Este método é razoável em termos de execução. De acordo com [Wils79] 96 por centos de todos acessos a variáveis e parâmetros, são acessos ao nível global ou nível corrente.

4. Pascal NBS implementa dois tipos de reais :REAL e LONGREAL. O tipo REAL é implementado em 32 bits, o tipo LONGREAL é implementado em 64 bits. O nosso compilador implementa apenas um tipo REAL em 16 bits sob forma de logaritmo por razões práticas. O método adotado é o sistema FOCUS que garante precisão de três dígitos significativos. Apesar desta precisão ser

pobre, esta implementação tem utilidade em alguns casos específicos. A execução do cálculo de números reais com este método é extremamente rápida em comparação aos métodos convencionais. Além disso, a implementação do sistema FOCUS é muito simples.

5. O compilador aceita 12 opções de compilação. A lista completa de opções estão no Apêndice C. Algumas opções, e.g. TRACE, SELECT, JUMP, PRINT, são importantes para verificar o código gerado pelo compilador.

## CAPITULO 2

### DESCRICAO DO PASCAL NSS

#### 2.1 A LINGUAGEM PASCAL

O primeiro Compilador Pascal foi implementado para o computador CDC 6400 em ETH(Zurique) em 1968. Varios outros compiladores Pascal proliferaram rapidamente nos ultimos dez anos. No ano 1978 existiam mais do que 2000 membros dos usuarios de compiladores Pascal em 31 paises.

O sucesso do Pascal e' atribuido a quatro caracteristicas principais da linguagem;

1. E' elaborada para programacao estruturada.
2. A sintaxe e a semantica do Pascal e' simples . Este fato induziu a grande facilidade em implementacao e maior confiabilidade do compilador. Os compiladores Pascal sao bem menores do que os compiladores das linguagens ALGOL 68, PL/I, COBOL, etc; e geram codigo mais compacto.
3. Permite declaracoes dos tipos de variavel, parametro e arquivo.
4. Possui alocacao dinamica de memoria.

Durante este periodo, varios dialetos do Pascal surgiram. Como a linguagem nao foi oficialmente padronizada, varios compiladores foram implementados para dialetos de Pascal. Ha' um movimento para padronizar o Pascal a nivel internacional[Reve79].

Surgiram varios sugestões de adicionar mais recursos para o Pascal;

1. Seletor "OTHERS" no comando CASE.
2. Omissão do comando GOTO e rotulos.
3. Declaração de constante estruturada.
4. Melhor formatação dos arquivos INPUT e OUTPUT.
5. Passagem de parâmetro do tipo vetor com tamanho variável( matrizes dinâmicas ).
6. Declaração OWN como definida em ALGOL.
7. Extensão de funções para leitura e escritura.
8. Acesso aleatório a arquivos.
9. Tipo "Cadeia de Caracteres" e operações correspondentes.

[Rich77].

## 2.2 DIFERENCA ENTRE PASCAL NBS E PASCAL ORIGINAL(ETH)

Ha' tres diferenças principais entre Pascal NBS e Pascal original. Estas diferenças são derivadas de restrições na arquitetura da máquina objeto PDP11. O PDP 11 possui apenas 64 K bytes de espaço lógico de memória. Quase todas as implementações do Pascal para microprocessadores enfrentam esta barreira e a solucionam de várias maneiras. Uma das soluções mais comuns é "OVERLAY". As três diferenças principais são as seguintes:

### 1. Constantes Estruturadas

Compiladores usam várias tabelas relativamente grandes. Estas tabelas são, de modo geral, do tipo estruturado, isto é, tipo registro ou tipo vetor de registros. A única maneira de inicializar este tipo de constante de sintaxe do Pascal original é fazer a atribuição de cada elemento da constante em tempo de execução. Esta maneira seria muito ineficiente em termos de memória porque a memória é gasta para gerar código de atribuição para inicialização da Constante Estruturada. A ideia de Constante Estruturada no Pascal NBS é tratar esta inicialização em tempo de compilação, de maneira mais elegante do que, por exemplo, o artifício de INITPROCEDURE adotado no Pascal do DEC 10. O exemplo abaixo mostra a maneira de declarar Constantes Estruturadas no Pascal NBS.

Exemplo:

```

TYPE      elem = RECORD
            n : ARRAY[ 1..2 ] OF char;
            b : boolean;
            i : integer
          END;

TYPE      cons = ARRAY[ 1 .. 2 ] OF elem;

VAR      vet : cons;

CONST
  tabela =
  cons('A8',true,1),('CD',false,2);

BEGIN

```

```

    vet:=((‘KL’,false,3),('XY',true,4));
END;

```

Em consequencia desta modificacao, a regra de ordem de declaracoes foi violada. O Pascal NBS permite numero variavel de declaracoes, em qualquer ordem, sendo os identificadores usados numa declaracao definidos anteriormente, exceto o identificador de tipo usado para declaracao de apontadores.

Esta sintaxe possui outras vantagens: alem de economizar a memoria para codigo, podemos agrupar declaracoes de identificadores de maneira mais conveniente, o que seria util para o melhor entendimento do programa.

Alem das Constantes Estruturadas, Pascal NBS permite declaracao de constante cujo valor e' uma expressao constante.

## 2. Comando LOOP

O comando GOTO e' omitido no Pascal NBS. Esta decisao foi tomada elaboradamente para simplificar o compilador. De acordo com Wilson[Wilts79], a linguagem Pascal-S possui 20 por cento menos de recursos da linguagem Pascal original e conseguiu retirar 70 por cento de complexidade em implementacao. O comando GOTO nao e' essencial do ponto de vista de programacao sistematica. O comando LOOP foi adicionado para enriquecer os recursos de programacao sistematica e, em certo sentido, para compensar a ausencia do comando GOTU.

A sintaxe do comando LOOP e' seguinte:

```

<comando LOOP> ::= LOOP
                  <seqcomando>
                  <seqexit>
                  END

<seqcomando> ::= <comando> { ; < comando > }

<seqexit> ::= <partexit> ! <partexit> <seqexit>

<partexit> ::= <exit> ! <exit> { ; <seqcomando> }

<exit> ::= EXIT IF <expbool> !

```

```
EXIT IF <expbool> THEN <comando>
```

O comando LOOP é um comando repetitivo similar aos comandos REPEAT e WHILE, exceto que a condição de saída pode estar em qualquer lugar do laço de repetição. Note que pode existir mais de um "EXIT" dentro do "LOOP", o que é diferente da implementação do comando LOOP no Compilador Pascal de Hamburgo, implementado no sistema DEC 10, e existem duas formas de saída do "LOOP". A semântica da segunda forma de saída do LOOP é, se a expressão booleana for verdade então executar o comando que segue o símbolo "THEN" primeiro e sair do LOOP. O comando LOOP resolve um problema típico das operações OR e AND em Pascal. Nas operações OR e AND, os dois operandos são calculados incondicionalmente. Existem muitos casos em que nos não queremos calcular o valor do segundo operando dependendo do valor do primeiro operando.

EXEMPLO :

```
i:=1;
WHILE (i <= 10) AND (v[i]<>n) DO
  i:=i+1;
```

Repare que quando o valor de i for 11, o valor da subexpressão (*i* <= 10) fica falso e refere-se a um elemento de vetor que está fora do limite de índice declarado (Supondo que o vetor v esteja declarado como ARRAY[1..10] OF INTEGER). Este trecho do programa pode ser reescrito elegantemente usando o comando LOOP.

```
i:=1;
LOOP
  EXIT IF i> 10 THEN writeln('Nao existe');
  EXIT IF v[i]=n THEN writeln('Existe');
  i:=i+1
END;
```

### 3. Extensão de comandos para alocação dinâmica de memória

Pascal NBS possui os comandos MARK e RELEASE que permitem fazer a coleta de lixo de memória (Garbage Collection) simples. O comando DISPOSE no Pascal de Hamburgo é equivalente ao comando RELEASE no Pascal NBS.

Exemplo:

```

VAR      apont : ^integer;
BEGIN          BEGIN
    •           •
    •           •
    NEW(apont);      MARK;
    •           •
    •           •
    DISPOSE(apont);   RELEASE;
    •           •
    •           •
END;          END;

```

Alem dos comandos MARK e RELEASE, o Pascal NBS possui uma terceira forma do comando NEW. As outras duas formas sao iguais as formas definidas no Pascal original. A terceira forma e' utilizada para economizar a memoria do tipo vetor de registros alocada de forma que somente os N primeiros elementos do vetor declarado neste tipo registro sao necessarios na alocacao.

#### Exemplo:

```

TYPE
  id = RECORD
    l : integer;
    str : ARRAY[1..80] OF char
  END;

VAR
  p : ^id;      i, n : integer;

BEGIN
  n:=15;
  NEW(p,n);
  WITH p^ DO
  BEGIN
    l:=n;
    FOR i:=1 TO n DO str[i]:=' '
  END
END;

```

Na chamada do comando NEW(p,n) do exemplo, apenas 15 posicoes do vetor str sao alocados. O seguinte parametros da chamada pode ser qualquer expressao. Este recurso e' indispensavel para montagem de arvore de sintaxe de cada procedimento a partir do Codigo-P feita no Passo 2 do Compilador NBS.

Existem algumas diferenças de sintaxe miscelâneas entre o Pascal NBS e o Pascal original:

1. Numa declaração de um vetor, os valores inferior e superior de índice podem ser declarados com expressão constante.
2. Os tipos dos parâmetros de procedimento ou função podem ser declarados na própria declaração de procedimento ou função.
3. Constante estruturada pode ser utilizada numa atribuição.

Exemplo:

```
TYPE      t = RECORD
          a : char;
          b : boolean
        END;

VAR      x : t;

BEGIN
  x:=t('P',true)
END;
```

## 2.3 Limitações na implementação do Compilador Pascal NBS

O compilador Pascal NBS possui uma série de limitações como outros Compiladores:

1. Os primeiros 15 caracteres num identificador são reconhecidos.
2. O número máximo de procedimentos declarados num programa é 150.
3. A profundidade máxima de encaixamento de procedimento é 15.
4. Os valores de seletores num comando CASE podem estar somente no intervalo de 0 .. 255.
5. A palavra "Packed" é ignorada.

6. A declaracao de parametros do programa principal(tipo arquivo) e' ignorada.
7. O tipo CHAR e' implementado em 3 bits e cobre o conjunto completo de ASCII que e' diferente da implementacao do Compilador Pascal no DEC 10.
8. O numero maximo de elementos num conjunto e' 16. Esta limitacao causa um problema serio do compilador NBS. Na maioria dos casos, recuperacoes de erros do Compiladores sao implementadas usando os recursos de conjunto cuja cardinalidade e' cerca de 60 a 70. Portanto, recuperacao de erros do Compilador NBS e' muito pobre , isto dificulta muito o uso do compilador na pratica.

## CAPITULO 3

### DESCRICAO DO CODIGO-P

O Código-P definido no compilador Pascal NBS é um tipo de código intermediário utilizado em compilação. Existem vários tipos de códigos intermediários. Quanto mais o código intermediário estiver próximo do código da máquina, a geração de código final, a partir desse código, ficará mais fácil. Por outro lado, este tipo de código possui apenas informações locais e isto dificulta a otimização do código objeto final.

O método mais convencionalmente adotado por compiladores de dois passos é definir cada código intermediário como uma instrução de uma máquina fictícia, orientada à pilha. [Amma73] As vantagens deste método são: a facilidade na geração de código e confiabilidade do código gerado.

O Código-P do Compilador Pascal NBS não é um código intermediário deste tipo, mas é uma imagem da árvore de sintaxe do programa fonte, que o Passo 1 analisou e codificada linearmente na memória. O Passo 2 monta a árvore de sintaxe explicitamente de cada procedimento a partir da sequência do Código-P antes de gerar o código final. Esta árvore de sintaxe facilita a otimização de código. A relação entre o Código-P e a árvore de sintaxe é explicada posteriormente. Teoricamente a otimização de código a partir do Código-P convencional é possível [Coli], [Corn].

Aém do mais, a exploração das características de operação, por exemplo, as associativas, causam problemas de "overflow", "underflow" e precisão. O Código-P convencional de uma expressão seria a cadeia de operandos e operações em Pos-ordem da árvore equivalente, porque o número de operandos de cada operação aritmética e lógica é sempre fixo. Existem alguns estudos muito

interessantes feitos sobre otimização do Código-P convencional.

### 3.1 CÓDIGO-P E ÁRVORE DE SINTAXE

Normalmente árvore de sintaxe não é uma árvore binária mas árvore livre. Árvore livre é uma árvore em que cada nó da árvore possui número variável de subárvore. Numa árvore que representa uma expressão aritmética e lógica, o número de subárvore de cada nó é constante. Porem existem vários tipos de árvores em que este número de subárvore é variável. Um comando composto, por exemplo, pode ter número não negativo qualquer de sub-comandos. A partir do Código-P convencional, i.e. a sequência de nós da árvore em Pos-ordem, não podemos reconstruir a árvore original. Precisamos apresentar mais informação ao Código-P para reconstruir a árvore. Esta informação seria o número de subárvore de cada nó. A cada Código-P está associado o número de subárvore do nó.

No inicio do Passo 2, é executado um algoritmo de reconstruir a árvore de sintaxe a partir de Código-P, que é relativamente simples. Uma pilha de apontadores é usada neste algoritmo.

Algoritmo :

- 1) Ler um código-P e alocar memória para o código
- 2) Se o número de subárvore deste código for zero empilha-lo no topo da pilha.  
Se não, retirar o número de subárvores deste código do topo da pilha, coloca-los como subárvore do código atualmente lido e colocar este código na pilha.

### 3.2 IMPLEMENTACAO DE CODIGO-P NO PASCAL NBS

Cada no' da arvore de sintaxe montada pelo Passo 2 e' definido da seguinte maneira:

```

CONST
  maxarg = 255;

TYPE
  byte = 0 .. 255;
  ptr = ^ node;
  node = RECORD
    code : byte;
    size : byte;
    disp : RECORD
      CASE boolean OF
        false : (disp : integer);
        true : (xval : fvalptr)
      END;
    segnr : byte;
    nnarg : byte;
    arg : ARRAY[1..maxarg] OF ptr
  END;

```

Cada campo de tipo NODE tem seguinte sentido:

1. **code**  
a numeracao do Código-P. A tabela completa de codigos implementados no compilador esta' no apendice A.
2. **size**  
Para variaveis ou parametros, o tamanho de cada elemento indicado pelo no' e' indicado neste campo. Para operacoes aritmetricacas e logicas, o tamanho do resultado calculado e' guardado. Para o Código-P INDEX que indica um endereco indexado, tamanho de cada elemento de vetor e' indicado.
3. **disp**  
Para variavel ou parametro do tipo scalar, este campo indica o deslocamento. Para valor literal o valor mesmo e' armazenado. Este campo esta' declarado como RECORD do tipo campo variante por uma razao. Numeros reais estao representados em 32 ou 64 bits. Para economizar o espaco de memoria o subcampo fvalptr aponta o endereco na area de HEAP onde este valor esta' armazenado.

**3. SEGNC**

Para variavel ou parametro, este campo indica o nivel lexico.

**4. NNRG**

Este campo indica o numero de subarvores este no' possui. Para codigos comuns isto nao e' necessario. Porem para os codigos SEG(Comando composto), LOOP etc, precisamos indicar o numero de subarvores.

**5. ARGS**

Os apontadores de raiz de subarvores do codigo estao armazenados neste campo. Repare que o tamanho de vetor declarado de 255. Para poder alocar apenas o numero de bytes necessarios para cada codigo, uma modificacao de sintaxe do comando NEW foi feita. Quando um comando composto tiver subcomandos maior do que de 255, o Passo 1 forca fechar os primeiros 255 subcomandos como um comando composto ficticio.

A tabela completa de código-P esta' no apendice A.

## CAPITULO 4

### ADAPTACAO DO COMPILADOR PARA A MAQUINA OBJETO

#### 4.1 CARACTERISTICAS RELEVANTES DO INTEL 8088

O microprocessador INTEL 8088 possui algumas caracteristicas favoraveis para geracao de codigo para a linguagem Pascal.

1. É uma maquina hibrida com operandos de um e dois bytes, isto é, possui instrucoes com operandos de tamanho de um e dois bytes. Esta caracteristica é extremamente importante, porque o proprio Pascal define tipos de tamanho de um e dois bytes. Em comparacao a microprocessadores de 8 bits, os microprocessadores hibridos de um e dois bytes possuem instrucoes mais poderosas. O tamanho de codigo gerado para o microprocessador MOTOROLA 5600, que é maquina de 8 bits para o comando, por exemplo,  $A[i]=B[i]$ , fica 52 bytes, enquanto o codigo gerado para o microprocessador MOTOROLA 6809, que é maquina hibrida, para o mesmo comando fica apenas 20 bytes[Fors79]. No caso do nosso compilador o tamanho do codigo gerado para este comando é 20 bytes. Implementacao de Compilador Pascal para uma maquina de 8 bits ficaria bastante limitada especialmente em termos de espaço de memoria. Esta é a razao principal porque o primeiro Compilador Pascal para o microprocessador INTEL 8088( Compilador de San Diego ) gera codigo interpretado.
2. Possui o espaço de memoria suficientemente amplo para trabalhar com o Compilador Pascal; permite a configuracao de um megabyte de memoria.
3. Possui varias instrucoes poderosas em relacao a maquina de um byte.  
Há tres grupos de instrucoes muito uteis na geracao de codigo para Compilador Pascal.

1. Grupo 1 : Instrucoes aritmetica e logica  
INTEL 8088 possui instrucoes de divisao e multiplicacao com sinal e sem sinal. Os operandos podem ser de tamanho de um byte e de dois bytes. Para ajustar o tamanho dos operandos, existem duas instrucoes: CSW e CWD.
2. Grupo 2 : Instrucoes para controle de lacos.  
Existem duas instrucoes que fazem controle de laco explicitamente por codigo: LOOP e REP. Estas instrucoes sao equivalentes aos comandos FOR, REPEAT e WHILE em Pascal. Porem nao usamos estas instrucoes na geracao de codigo em geral, porque estas instrucoes requerem o uso especifico do registrador CX. Normalmente o registrador CX e' utilizado na execucao dos comandos dentro dos comandos FOR, REPEAT, e WHILE. Alema disso, encaixamento dos comandos repetidos na linguagem Pascal nao podem ser implementados atraves destas instrucoes repetitivas do INTEL 8088. As instrucoes repetitivas sao usadas nas subrotinas de suporte de execucao.
3. Grupo 3 : Instrucoes para manipulacao de cadeia de caracteres.  
Estas instrucoes sao extremamente uteis para gerar codigo de comandos do tipo A=B onde A e B sao vetores ou do tipo registro. Uma comparacao de vetores, tambem, pode ser implementada por este tipo de instrucao. Outro exemplo e' passagem de vetor como parametro com valor.
4. Nao ha' problemas de alinhamento de palavra como no caso do PDP 11. O compilador NBS original e' obrigado fazer alinhamento. Como INTEL 8088 nao tem este problema, o nosso compilador pode aproveitar a memoria melhor.
5. Possui instrucoes aritmeticas com valores literais operando diretamente sobre a memoria.  
Estas instrucoes sao:  
ADD, SUB, INC, DEC, NEG, OR, AND, NOT, etc.  
Elas podem ser usadas para geracao de codigo de comandos como os seguintes:

```
i:=succ(i);
A[i,j]:=A[i,j] - 10;
p@.x:=-p@.x;
```

Todos esses comandos sao comandos de atribuicao. Este tipo de atribuicao e' especifico porem a frequencia de atribuicoes deste tipo em programas escritos em Pascal nao e' insignificante. Descricao detalhada do uso de instrucoes deste tipo e' feita na parte de geracao de codigo.

O INTEL 8086 apresenta tambem varios problemas:

1. Os registradores nao sao de proposito geral
2. As instrucoes de salto condicional tem apenas um byte para representar o deslocamento relativo de salto.
3. Nao existe instrucoes de PUSH de valores literais. Este tipo de instrucoes sao desejaveis para gerar o codigo de chamada de procedimento ou funcao com parametros passados por valor do tipo literais.

Observamos que o Compilador nao utiliza todas as instrucoes do INTEL 8086. Apenas 80 % delas sao utilizadas. As instrucoes nao utilizadas sao principalmente as instrucoes relacionadas com funcoes do sistema operacional, e.g. HLT, WAIT, ESC, PUSHF, POPF,etc[Fors79], [Hart80].

#### 4.2 ALLOCACAO DE REGISTRADORES

O INTEL 8088 possui 12 registradores, usados da seguinte forma:

1. AX | AH | AL | I

Usado para calculo de expressoes.

2. CX | CH | CL | I

Idem ao AX. Mas usado para armazenar os valores temporarios de calculo de operacoes binarias. Tambem e' usado para os comandos repetitivos.

3. BX | BH | BL | I

Usado para carregar o endereco efetivo de variaveis ou parametros.

4. DX | DH | DL | I

Usado apenas para divisao e multiplicacao.

5. SP | I

Apontador de pilha.

6. BP | I

Usado para o apontador de nivel do procedimento ou funcao corrente na pilha( LOCAL POINTER ).

7. DI | I

Registrador de uso auxiliar. Usado tambem para operacao do tipo transferencia de cadeias.

8. SI | I

Idem ao DI.

#### 4.3 ENDERECAMENTO E ALLOCACAO DE MEMORIA

##### 4.3.1 Alocacao De Memoria Para Cada Tipo

Alocacao de memoria para tipo e' feita em bytes no Compilador Pascal NBS. Como o microprocessador INTEL 8088 e' maquina que endereca a nivel de byte, compactacao em alocacao de memoria nao teria sentido. Portanto todas as palavras PACKED no programa fonte sao reconhecidas, mas ignoradas pelo compilador. Existe um detalhe neste caso, o tipo CHAR e' representado por um byte no Compilador NBS enquanto um caracter no vetor compactado ou arquivo compactado do tipo char do Compilador Pascal de Hamburgo e' representado por 7 bits. A definicao do tipo CHAR no Pascal NBS contem o conjunto ASCII enquanto a definicao do Pascal de Hamburgo e' um subconjunto de ASCII. Em muitos casos, o tipo CHAR do Pascal NBS e' utilizado como se fosse um tipo INTEGER de um byte(e.g. SHORTINTEGER do MODULA). A seguinte tabela mostra alocacao de memoria para cada tipo:

SCALAR.....	1 byte
BOOLEAN.....	1 byte
CHAR.....	1 byte
INTEGER.....	2 bytes
LONGINTEGER...	4 bytes
REAL.....	2 bytes
LONGREAL.....	2 bytes
SET.....	1 ou 2 bytes
POINTER.....	2 bytes
FILE.....	522 bytes

O tipo LONGINTEGER definido no Pascal NBS nao foi implementado. O tipo SET pode ser representado por um byte ou dois bytes, dependendo a cardinalidade do conjunto. A cardinalidade maxima de um conjunto e' 16 no Pascal NBS. Todas as entradas e saidas do programa sao feitas atraves do terminal, apenas. Os 512 bytes do tipo FILE sao utilizados como BUFFER de entrada ou saida e 10 bytes sao utilizados para representar o estado do BUFFER do arquivo,e.g. apontador no buffer, estado de EOLN e EOF, tamanho de cada registro do arquivo, etc. O tipo definido pelo RECORD depende dos tipos de subcampos. Como o Compilador NBS faz alinhamento de enderecos devido ao problema do PDP 11, a ordem de declaracao de subcampo influencia o espaco de memoria alocado para este tipo RECORD, mesmo definindo os mesmos subcampos de tipos iguais. O tipo REAL e' tratado de maneira bem diferente aos outros tipos. Uma variavel do tipo REAL, por exemplo, nao representa seu valor, mas aponta o endereco onde este valor esta' representado na area de

HEAP por 4 bytes. O tipo LONGINTEGER e' representado por 8 bytes na area de HEAP.

#### 4.3.2 Enderecos De Constantes, Variaveis E Parametros.

##### 1. Constantes

As constantes simples, e.g. integer, boolean, char, real, sao guardados na tabela de simbolos do Passo 1 do compilador. Todas as constantes do tipo estruturado (incluindo o tipo cadeia) sao agrupadas e guardados numa area reservada na memoria, e eles sao associados a deslocamento relativo a partir do inicio desta area. Portanto o acesso a uma constante e' sempre direto. O compilador Pascal NBS original gasta um pouco mais memoria para guardar as constantes, porque o PDP 11 tem problema de alinhamento.

##### 2. Variaveis

Variaveis e parametros sao enderecados por dois argumentos; nivel corrente da rotina e deslocamento relativo do nivel corrente da pilha. Para aumentar a eficiencia na geracao de codigo, variaveis globais do programa( nivel lexico 1 ) sao acessadas diretamente. A memoria para variaveis globais e' estaticamente alocada e desalocada apenas no momento em que o programa termina. Como a frequencia com que variaveis globais sao referenciadas e' bastante alta em relacao as variaveis locais de rotinas, este tipo de otimizacao e' muito importante. As variaveis globais sao enderecadas com deslocamento positivo e as variaveis locais de rotinas sao enderecadas com deslocamentos negativos enquanto todos os parametros, a menos os parametros do programa fonte do tipo arquivo, que sao ignorados pelo Compilador, sao enderecados com deslocamentos positivos.

##### 3. Parametros

Os parametros sao enderecados com deslocamentos positivos. Como no caso de variaveis, os enderecos sao alinhados. Este alinhamento foi intencionalmente deixado porque o INTEL 8088 nao possui a instrucao PUSH de um byte. Se compactar o enderecamento de parametros, a geracao de codigo para passagem de parametros ficaria muito cara. O parametro do tipo vetor passado por valor nao e' empilhado inteiramente na pilha na chamada, mas e' passado apenas o endereco inicial do vetor. Este tipo de parametro e' tratado como se fosse uma variavel local da rotina que esta sendo chamada e seus valores de vetor sao copiados na entrada da rotina.

## 4.4 MAPA DE MEMÓRIA

```
*****  
*  
*      MAPA DE MEMÓRIA DURANTE EXECUÇÃO NO INTEL 8088  
*  
*****
```

```
I ======I  
I           I  
I MONITOR DO INTEL 8088 I  
I     ( EPROM )       I  
I           I  
OF000 I ======I  
I           I  
I         MEMÓRIA       I  
I           I  
I         INEXISTENTE   I  
I           I  
7FFFFF I ======I  
I         STACK AREA    I <== INÍCIO DO "STACK"  
I     . . . . .          I  
I     . . . . .          I  
I     . . . . .          I  
I           I  
I           I  
I           I  
I     . . . . .          I  
I     . . . . .          I  
I           I  
I         HEAP AREA     I <== INÍCIO DO "HEAP"  
I ======I  
I           I  
I VARIÁVEIS GLOBAIS I  
I     E               I  
I BUFFERS DE E/S      I  
I           I  
I ======I  
I           I  
I CONSTANTES          I  
I           I  
I ======I  
I           I  
I MENSAGENS NA EXEC  I  
I           I  
I ======I  
I     HEAP POINTER      I  
I ======I  
I           I  
I AREA RESERVADA P/   I  
I     MARK E RELEASE    I
```

```
I I
I=====I
I      DISPLAY 1   I
I      DISPLAY 2   I
I      DISPLAY 3   I
I      . . . . .
I      . . .
I      DISPLAY 15  I
I=====I
I      I
I      SUBROUTINAS P/   I
I      RUNTIME SUPPORT I
I      I
I=====I
I      I
I      TABELA P/ FOCUS I
I      (PONTO FLUTUANTE) I
I      I
I=====I
I      BUFFER P/ MANIPULACAO I
I      DESTA TABELA   I
I=====I
09FH    I      I
I      USADO PELO MONITOR   I
I      DO INTEL 8088       I
I      I
000H    I=====I
```

#### 4.5 ROTINAS DE SUPORTE DURANTE EXECUCAO

Existem 38 rotinas INTRINSECAS:

##### Tabela de rotinas INTRINSECAS

1 .. Get	2 .. Put	3 .. Break	4 .. Position
5 .. Reset	6 .. Rewrite	7 .. Update	8 .. Read
9 .. Readln	10 .. Write	11 .. Writeln	12 .. Eof
13 .. Eoln	14 .. New	15 .. Free	16 .. Mark
17 .. Release	18 .. Pred	19 .. Succ	20 .. Any
21 .. All	22 .. Odd	23 .. Ord	24 .. Chr
25 .. Float	26 .. Round	27 .. Max	28 .. Min
29 .. Ceil	30 .. Floor	31 .. Abs	32 .. Sqr
33 .. Sqrt	34 .. Ln	35 .. Exp	36 .. Sin
37 .. Cos	38 .. Arctan		

O numero de cada rotina corresponde a sua numeracao interna no compilador NBS. As rotinas POSITION e UPDATE sao usados para implementar arquivos de acesso randomico(RANDOM ACCESS FILES). Este recurso nao esta implementado. A funcao FLOOR(m,n:integer):integer e' definida da seguinte maneira:

FLOOR:=m DIV n \* n

A funcao CEIL(m,n:integer):integer e' definida da seguinte maneira:

CEIL :=(m + (n-1)) DIV n \* n

As funcoes FLOOR e CEIL sao utilizadas para o calculo de numero de bytes alocados para cada tipo(especialmente tipo indexado).

No momento, entrada e saida de arquivos nao estao bufferizadas, portanto a rotina BREAK, GET, PUT, RESET, REWRITE, EOF nao estao implementadas.

A funcao ANY(s:tipo conjunto):tipo scalar, devolve o primeiro elemento do tipo scalar que pertence ao parametro do tipo conjunto.

Todas as funcoes do tipo real nao estao implementadas tambem.

As rotinas implementadas estao detalhadas no Apendice B. As rotinas de suporte durante execucao estao escritas em linguagem de montagem do INTEL 8088. Uma maneira de carregar as rotinas e' montar as rotinas independentemente e pedir ao carregador para carregar no endereco predefinido.

Como o sistema INTEL 8086 está monoprogramado por enquanto, esta maneira funcionaria bem. Porem decidimos copiar as rotinas que estão escritas em linguagem de montagem para a saída do Passo 2 no inicio da execução do Passo 2 para evitar erros causados pelo carregador. Uma maneira mais eficiente de copiar as rotinas seria copiar apenas as rotinas que são necessárias para execução do programa. Porem o Passo 2 copia todas as rotinas no momento.

## CAPITULO 5

### OTIMIZACAO E GERACAO DE CODIGO

#### 5.1 EXPRESSOES

Uma maneira natural de representar uma expressao e' em notacao polonesa. A notacao polonesa possui recursividade implicita. O mecanismo para calcular uma expressao em notacao polonesa usa implicitamente uma pilha. Existem alguns computadores orientados a pilha como Burroughs 5800. Ha' tres metodos popularmente adotados para gerar codigo a partir de uma expressao polonesa. A ideia basica dos tres metodos e' implementar em software as operacoes de pilha que o hardware do computador nao possui.

Metodo 1 : Gerar codigo que e' interpretado numa linguagem implementada no computador. Este metodo e' mais facil e adotado em varios compiladores com o Compilador Pascal de San Diego(UCSD). A vantagem deste metodo e' economia de memoria especialmente quando implementado para microprocessadores de 8 bits. Geracao de codigo de maquina para operacoes com operandos de 16 bits para este tipo de processador ficaria cara em termos de memoria[Ullm70]. A desvantagem principal deste metodo e' o tempo de execucao bastante demorado. Normalmente, execucao de um programa interpretado leva tempo na faixa de dez a cinquenta vezes maior do que o programa equivalente executado por codigo compilado. Portanto, se um compilador for implementado com este metodo ele levaria muito tempo para se auto-compilar.

Metodo 2 : Implementar as operacoes de pilha atraves de macros em linguagem de montagem. Este metodo e' superior ao Metodo 1 em termos de tempo de execucao. Porem o codigo gerado fica muito grande. Este metodo e' impraticavel quando implementado num microprocessador com espaco de memoria restrito.

Metodo 3 : Implementar as operacoes de pilha atraves de chamadas de subrotinas. Esta tecnica e' chamada THREADED CODE. Este metodo e' vantajoso em relacao ao Metodo 2 em termos de memoria. Por outro lado, o calculo de expressao leva mais tempo do que o Metodo 2 devido a passagem de parametros, desvio para chamada e retorno de cada subrotina[Bell73].

O metodo adotado e' diferente dos tres, porque todos eles nao resolvem o problema basico de que a expressao polonesa e' destinada a maquina orientada a pilha e a nossa maquina e' uma maquina de um endereco(ONE-ADDRESS-MACHINE). O problema que queremos resolver e' gerar codigo de maquina eficiente para expressoes para uma maquina de um endereco. A nossa solucao e' deixar os valores do topo da pilha em registradores em vez de na propria pilha.

Geracao de codigo e' feita atraves da arvore de sintaxe explicitamente montada. Os valores do topo da pilha representam os valores das subexpressoes correntemente calculadas. Sendo estes valores guardados em registradores, operacoes sobre os valores do topo da pilha podem ser feitas diretamente.

O microporcessador INTEL 8088 possui cinco formas de operacoes basicas:

- A - op [ reg1 , reg2 ] => reg1
- B - op [ reg1 , memoria ] => reg1
- C - op [ reg1 , literal ] => reg1
- D - op [ memoria , reg ] => memoria
- E - op [ memoria , literal ] => memoria

As tres primeiras formas sao importantes na geracao de codigo para expressoes. As outras formas sao utilizadas na geracao de codigo para atribuicoes, o que sera explicado posteriormente. Nem todas as formas sao permitidas para todas as operacoes no INTEL 8088. Este problema sera detalhadamente discutido no fim da descricao de geracao de codigo para expressoes.

Sendo os valores de TOP0 - 1 e TOP0 da pilha guardados nos registradores reg1 e reg2 respectivamente, uma operacao binaria da forma A emula uma operacao binaria na pilha. As operacoes de formas B e C sao equivalentes a' forma A quando o valor de reg2 contem um valor de variavel simples ou valor literal. Uma operacao binaria da forma B, por exemplo, poderia ser feita com a sequencia de operacoes:

```
reg2           <= memoria  
op[reg1 , reg2] => reg1
```

A vantagem de operacoes das formas B e C sobre a sequencia acima e' nao precisar empilhar o segundo operando, i.e. carregar o operando em registrador.

Apenas dois registradores AX e CX sao usados para o calculo de expressoes pelas seguintes razoes:  
Os registradores BX, BP, SP sao reservados para calculo de endereco, apontador de nivel da pilha da rotina corrente, e topo da pilha respectivamente. O registrador DX nao e' apropriado para armazenar valores porque o seu valor e' alterado depois de uma operacao de multiplicacao ou divisao quando os operandos forem de dois bytes. Os registradores DI e SI nao permitem operacoes sobre byte e sao usados para operacoes de vetores ou cadeia de caracteres; alem disso eles sao usados para fins auxiliares. Como multiplicacao de AX por um valor literal nao e' permitido no INTEL 8088, o valor literal e' carregado primeiramente no registrador DI ou SI o que acontece comunmente no calculo de endereco de matrizes.

Em muitos compiladores, alocacao de registradores para cada operacao e' feita atraves de analise da expressao antes de geracao de codigo final. Este metodo nao e' facilmente aplicavel pelas razoes citadas anteriormente. Portanto adotamos alocacao de registradores da maneira mais simples para obter maior confiabilidade no codigo gerado.

### 5.1.1 Algoritmo Geral De Optimizacao e Geracao De Codigo

[Algoritmo para geracao de codigo para uma arvore de expressao usando N registradores de proposito geral]

Primeiramente o algoritmo para N registradores "gerais" e' citado e explicamos a adaptacao deste algoritmo para o nosso caso particular.

A palavra "geral" possui os seguintes sentidos:

1. Qualquer registrador pode ser usado para todas as operacoes das formas A, B, e C.
2. Todas as operacoes binarias permitem as tres formas A, B, e C.
3. Todos os registradores permitem as operacoes binarias sobre um e dois bytes.

Em primeiro lugar, precisamos introduzir o algoritmo descendente recursivo de rotulacao dos nos da arvore de expressao. O valor do rotulo do no' significa o numero de registradores necessarios para gerar codigo da subarvore cuja raiz e' esse no'[Ullm70].

Como o caso de operacoes unarias e' bastante simples, discutimos apenas os casos em que todas as operacoes da expressao sao binarias.

#### Algoritmo 1

[Algoritmo para rotular os nos da arvore de expressao]

Notacao :  $l(P)$  e' o valor atribuido ao no' P.

1. Quando o no' P for folha, i.e. variavel simples ou valor literal , existem dois casos:
  1. P e' descendente 'a esquerda  
 $l(P) = 1$
  2. P e' descendente 'a direita  
 $l(P) = 0$
2. Quando P tiver duas subarvores com rotulos 11 e 12, existem dois casos:

1.  $l_1 \leftarrow l_2$   
 $l(P) = \max(l_1, l_2)$

2.  $l_1 = l_2$   
 $l(P) = l_1 + 1$

Exemplo:  $a/(b+c)-d*(e+f)$

Aproveitando a propriedade de operacoes comutativas, podemos diminuir o valor de rotulo do no' em certos casos. Quando a operacao do no' for comutativa, podemos trocar as subarvores esquerda e direita do no' mantendo o mesmo resultado da expressao representada pelo no'.

Exemplo:  $(A+(B+C))$   $((B+C)+A)$

O algoritmo descendente recursivo de modificar arvore de sintaxe para diminuir o valor de rotulo de expressao em termos de operacoes comutativas e' seguinte.

Algoritmo 2

1. Se o no' P for uma folha retorna l(P)
2. Aplicar este algoritmo para subarvore esquerda do no'.
3. Aplicar este algoritmo para subarvore direita do no'.
4. Se a raiz da arvore for operacao binaria, e se a operacao for comutativa e o valor do rotulo da raiz da subarvore esquerda for menor do que o valor do rotulo da raiz da subarvore direita, entao trocar as duas subarvores do no' da expressao corrente.

Aplicando este algoritmo para a expressao do exemplo anterior;

$a/(b+c)-d*(e+f)$   
obtemos a seguinte expressao equivalente.

$$a/(b+c) - (e+f)*d$$

Este algoritmo pode diminuir o valor do rotulo da expressao, porem nao necessariamente e' otimo porque o algoritmo e' aplicado para operacoes comutativas apenas. Existem outras maneiras, por exemplo modificacao de arvore sobre operacoes associativas, que diminuem o valor de rotulo da raiz da arvore. O exemplo a seguir mostra um caso em que o rotulo da arvore pode ser diminuido atraves de outro tipo de modificacao da arvore.

Exemplo:

$$a-(b-c)$$

$$(a+c)-b$$

Neste exemplo, otimização de rotulacão da árvore é feita sobre operações não-comutativas e não-associativas. Matematicamente, as duas expressões  $a-(b-c)$  e  $(a+c)-b$  são equivalentes, porém quando os valores  $a, b$  e  $c$  forem suficientemente grandes, o cálculo de  $(a+c)$  pode causar overflow. De modo geral, este tipo de otimização de rotulo da árvore não é preferível em termos de precisão especialmente quando os operandos da árvore forem do tipo real.

[ Otimização do rotulo da árvore de expressão através de operações associativas ]

Exemplo:

$$(a+b)+(c+d) \quad (((a+b)+c)+d)$$

Neste exemplo, troca de subárvores esquerda e direita não consegue diminuir o rotulo da árvore. Aproveitando a propriedade associativa de operações, podemos diminuir o valor do rotulo da árvore. Primeiramente precisamos definir a palavra "cluster". O cluster é a subárvore maximal da árvore de expressão em que cada nó interno possui a mesma operação associativa. Observe que os nós externos podem ser

expressões. Supondo, por exemplo, um cluster C tem 5 subárvores e1, e2, e3, e3, e4, e5 sobre uma operação OP, C pode ser modificado numa forma de lista L de subárvores sobre OP equivalente a C da seguinte forma:

$$C = ( (e1 \text{ OP } (e2 \text{ OP } e3)) \text{ OP } (e4 \text{ OP } e5) )$$

$$L = (((e1 \text{ OP } e2) \text{ OP } e3) \text{ OP } e4) \text{ OP } e5)$$

Repare que o valor do rotulo da lista L de subárvores sobre OP associada ao conjunto de subexpressões {e1, e2, e3, e4, e5} é  $\max(l(e1), l(e2), l(e3), l(e4), l(e5))$  ou  $\max(l(e1), l(e2), l(e3), l(e4), l(e5)) + 1$  de acordo com o algoritmo de rotulacão citado anteriormente enquanto que o valor do rotulo da árvore original pode ser maior do que o valor maximo da lista L.

O algoritmo de otimização de rotulo de árvore em termos de operações comutativas e associativas é descendente recursivo:

### Algoritmo 3

1. Obter o cluster da raiz da árvore correntemente aplicada. (O algoritmo é bastante simples e será omitido).
2. Para cada nó externo do cluster, aplicar este algoritmo recursivamente e obter o valor do rótulo da cada subexpressão.
3. Modificar este cluster para a forma de lista de subárvore como no exemplo citado anteriormente.
4. Buscar a subexpressão cujo valor de rótulo é máximo no cluster obtido e trocar esta subexpressão com a subexpressão mais esquerda da lista.

Este tipo de otimização não foi feita no nosso caso. A razão é bastante simples. A frequência que este tipo de otimização ocorre seria muito pequena na prática e não compensaria implementá-la especialmente quando escrevemos para uma máquina que possui espaço de memória bem restrito.

Depois da aplicação do algoritmo para diminuir o valor de rótulo da árvore através de operações comutativas, a árvore modificada possui a seguinte característica. Para qualquer nó da árvore cuja operação for comutativa, o valor do rótulo da subárvore direita do nó é menor ou igual ao valor do rótulo da subárvore esquerda. O algoritmo para gerar código a partir da árvore otimizada é descendente recursivo. Para melhor entendimento, suponhamos que o número de registradores é ilimitado primeiro.

#### Algoritmo 4

1. Quando  $l(P)$  do nó da árvore  $P$  sendo analizada é 0,  $P$  só pode ser uma variável ou parâmetro simples ou valor literal e também subárvore esquerda de uma expressão maior.

Alocar um registrador  $r1$  e gerar o código do tipo  
`MOV r1, [P]`

2. Quando  $l(P) > 0$   
 O nó  $P$  possui uma operação binária.  
 Alocar um registrador  $r1$   
 Aplicar este algoritmo para subárvore esquerda do nó  $P$  e carregar o valor no registrador  $r1$ .

1. Quando  $l(\text{dir}(P)) = 0$ 

Neste caso nao precisamos alocar registrador para subarvore direita do no' P.

Gerar o codigo do tipo  
OP r1 , dir(P)

2. Quando  $l(\text{dir}(P)) > 0$ 

Alocar um registrador r2

Aplicar este algoritmo para subarvore direita do no' P e carregar no registrador r2.

Gerar o codigo do tipo  
OP r1 , r2

Deallocar o registrador r2.

Na maioria dos casos, a modificacao da arvore e' feita implicitamente. Nao precisamos trocar as subarvores esquerda e direita para otimizar o valor do rotulo da arvore, so basta decidir a ordem de gerar codigo para subarvores. Porem, no nosso caso, o compilador modifica a arvore explicitamente antes de geracao de codigo por dois motivos:

1. Para facilitar outros tipos de otimizacoes miscelaneas.
2. Para facilitar verificar o processo de otimizacao da arvore (depuracao do compilador).

Este algoritmo garante que o numero de registradores necessarios para gerar codigo a partir de arvore e' otimo em termos de operacoes comutativas. A prova rigorosa da teoria e' escrita no livro "Compiler Techniques" [Ullm70].

O algoritmo de otimizacao com N registradores e' um pouco diferente dos algoritmos citados anteriormente. A ideia basica do algoritmo e' definir registradores ficticos de memoria para obter numero ilimitado de registradores.

### Algoritmo 2

Ao gerar o codigo para uma arvore apontada por P, se os dois rotulos das subarvores esquerda e direita de P estiverem

maiores do que N, alocar um registrador ficticio e aplicar o algoritmo 4[Ano77].

De acordo com Ullman[Ullm70], a troca de subarvores de P nao otimiza o codigo mesmo que  $l(esq(P))$  seja menor do que  $l(dir(P))$  se os dois rotulos forem maiores do que N, o que faria diferenca com o algoritmo 2. Ullman sugere gerar o codigo para a subarvore direita primeiro.

### 5.1.2 Otimizacao E Geracao De Codigo Adotadas No Passo 2

Apenas o registrador AX e' usado para calcular expressoes. Neste sentido, o numero de registradores utilizados e' um. Porem o registrador CX e' usado para armazenar o valor temporario de subexpressoes tambem.

A diferenca entre algoritmo 5 e o algoritmo adotado e' que as instrucoes PUSH e POP sao utilizadas ao inves da instrucao MOV. Como o algoritmo de gerar codigo e' descendente recursivo, os registradores ficticios alocados seguem uma pilha. As instrucoes PUSH e POP ocupam apenas 1 byte enquanto a instrucao MOV ocupa 3 bytes e sao mais rapidas do que MOV.

[ Algoritmo para otimizar arvores de expressoes ]

#### Algoritmo 6

Para uma arvore apontada por P,  
Se operacao de P for

1. Operacao unaria  
Otimizar a subarvore de P
2. Operacao binaria
  1. Aplicar este algoritmo para subarvore esquerda
  2. Aplicar este algoritmo para subarvore direita
  3. Se operacao e' comutativa e  
 $l(esq(P)) < l(dir(P))$  e  
 $l(esq(P)) < 2$   
Entao trocar subarvores esquerda e direita de P

A definicao de operacoes comutativas do Passo 2 e' diferente da definicao convencional. O Passo 2 reconhece operacoes semi-comutativas; e.g. <, <=, >, >= etc, como se fosse comutativas trocando o codgo da operacao.

Exemplo :

$$EXP1 < EXP2 \iff EXP2 > EXP1$$

Existe um detalhe ao trocar subarvores esquerdas e direitas do P no algoritmo 6, i.e. efeitos colaterais. Se a subarvore esquerda de P tiver chamadas de rotinas, entao as duas subarvores nao devem ser trocadas.

#### [ Algoritmo para gerar codigo a partir de arvore ]

Existe um procedimento chamado LOADAX(P:PTR) que gera o codigo da arvore apontada pelo parametro P. Como todos os calculos sao feitos pelo registrador AX apenas, o valor da arvore de expressao sempre e' carregado no AX. A ideia basica do algoritmo e' ao calcular uma operacao binaria de P, deixar sempre os valores de subarvores esquerda e direita nos registradores CX e AX respectivamente.

```
!
!
!=====
!
!      ! <= AX
!=====
!
!      ! <= CX
!=====
!
!  ... !
!=====
!
!  ... !
!=====
```

A geracao de codigo e' feita sempre para a subarvore esquerda primeiro. Para operacoes de subtracao e divisao, seria mais conveniente gerar codigo para subarvore direita primeiro. Porem se a subarvore esquerda tiver chamadas de rotinas, este metodo poderia causar efeitos colaterais.

#### [ Geracao de codigo para arvore apontada por P ]

##### **Algoritmo 7**

Existem tres casos:

1. P aponta para arvore de variavel ou valor literal
  1. Carregar o valor no registrador AX
2. P aponta para uma arvore unaria

1. Gerar codigo para subarvore
  2. Gerar codigo UNIDP AX
3. P aponta para uma arvore binaria
1. Aplicar este algoritmo para subarvore esquerda de P
  2. Existem dois casos em termos da subarvore direita do P
    1. Variavel ou valor literal  
Gerar o codigo BINOP AX , (dir(P))
    2. Nao e' variavel ou valor literal.  
Existem dois casos em termos de rotulo da subarvore direita de P, l(dir(P)).
      1.  $l(\text{dir}(P)) < 2$ 
        1. Gerar o codigo XCHG AX , CX
        2. Aplicar este algoritmo para subarvore direita de P
        3. Gerar o codigo BINOP AX , CX
      2.  $l(\text{dir}(P)) \geq 2$ 
        1. Gerar o codigo PUSH AX
        2. Aplicar este algoritmo para subarvore direita de P
        3. Gerar o codigo POP CX  
(Neste caso XCHG AX, CX e' feita implicitamente)
        4. Gerar o codigo BINOP AX , CX

Ao gerar o codigo BINOP AX , CX , se a operacao binaria e' subtracao ou divisao precisamos gerar o codigo XCHG AX , CX antes.

Exemplos :

a+b                    MOV AX , a

	ADD AX , b
a*(b+c)	MOV AX , b ADD AX , c IMUL WORD a
(a+b)*(c+d)	MOV AX , a ADD AX , b XCHG AX , CX MOV AX , c IMUL WORD d IMUL AX , CX
(a+b)+(c-d)	MOV AX , a ADD AX , b XCHG AX , CX MOV AX , c SUB AX , d ADD AX , CX
((a+b)-(b-c))+((a DIV b))	MOV AX , a ADD AX , b XCHG AX , CX MOV AX , b SUB AX , c XCHG AX , CX SUB AX , CX XCHG CX , AX MOV AX , a IDIV WORD b ADD AX , CX
((a+b)-(b-c))-((a div b)+((c*d)))	MOV AX , a ADD AX , b XCHG AX , CX MOV AX , b SUB AX , c XCHG AX , CX SUB AX , CX PUSH AX MOV AX , a IDIV WORD b XCHG AX , CX MOV AX , c IMUL WORD d ADD AX , CX POP CX XCHG AX , CX SUB AX , CX

Um detalhe importante deste algoritmo e' o ajuste de tamanho de operandos. A linguagem Pascal permite operacoes com tipos diferentes como o exemplo a seguir.

Exemplo :

i + ORD(ch)	MOV AX , i
	XCHG AX , CX
	MOV AL , cn
	XOR AH , AH ; Zerar AH
	ADD AX , CX
ch:=CHR(i+ORD(ch))	MOV AX , i
	ADD ch , AL

## 5.2 GERACAO DE CODIGO PARA ENDEREÇOS

Existem nove tipos de Código-P definidos para calculo de enderecos no Compilador Pascal NBS:

### 1. REGER :

Pseudo código. Indica que o resultado nao e' o conteudo do endereco calculado mas o endereco mesmo.

### 2. DESEI :

Código para calcular o deslocamento de um subcampo de uma variavel ou parametro do tipo registro indexado.

### 3. INDIR :

Código para calcular o endereco indicado por apontadores.

### 4. INDEX :

Código para calcular o endereco de um campo de vetores.

### 5. RIEIMP :

Código que indica o endereco que e' implicitamente indicado dentro do comando WITH.

### 6. RDATA :

Código que indica o endereco inicial de constantes do tipo estruturado.

### 7. VARBL :

Código que indica o endereco de uma variavel.

### 8. PARAM :

Código que indica o endereco de um parametro.

### 5.2.1 VARBL , PARAM

Existem tres casos possiveis em termos de nivel lexico:

#### 1. Nivel lexico = 1

Como os parametros do programa i.e. os arquivos usados no programa, sao ignorados pelo compilador, apenas variaveis globais podem ser referidas com nivel lexico um. Este endereco e' referido diretamente com o deslocamento do endereco inicial da area de memoria alocada(0LX18BASE) para variaveis globais do programa.

#### 2. Nivel lexico = Nivel corrente da rotina

O registrador BP foi alocado como LOCAL PCINTER i.e. o nivel da pilha da rotina correntemente compilada. Logo referencia neste caso e' feita atraves do registrador

SP.

3. Nivel lexico <> Nivel corrente da rotina  
Como o DISPLAY do nivel lexico da rotina corrente nao  
esta' em nenhum registrador, o acesso deve ser feito em  
dois passos. Primeiramente carregar o DISPLAY do nivel  
no registrador BX e calcular o endereco atraves deste  
valor no BX e o deslocamento.

Exemplo :

```
PROGRAM test;
VAR      k : integer;

PROCEDURE p( l : integer);

  PROCEDURE q;
  VAR m : integer;
  BEGIN
    k:=10;
    l:=20;
    m:=30
  END;

  BEGIN
  END;

BEGIN
END.
```

Codigo gerado para atribuicoes:

```
-----
k:=10  => MOV WORD LX1BASE+26 , 10
           . .
           26 e' deslocamento de k

l:=20  => MOV BX , DSP3
           Carregar o display no BX
           MOV WORD 4[BX] , 20
           4 e deslocamento de l

m:=30  => MOV WORD -2[BP] , 30
```

### 5.2.2 RDATA

O Passo 1 calcula o espaço de memória necessário para os constantes do programa inteiro. O endereço é calculado através do endereço inicial da área reservada para os constantes(@DATASE) e o deslocamento da constante.

Exemplo:

```
PROGRAM RDATA;
CONST str = 'ABC';
VAR v : ARRAY[1..3] OF char;
BEGIN
  v:=str
END.
```

Arvore montada para v:=str

```
-----  
MOVEM size : 3  
  VARSL v  
    RDATA str
```

Código gerado

```
-----  
MOV DI , @ (Endereco de v)  
; @ significa imediato  
MOV SI , @ (endereço de str)  
MOV CX , 3  
REP  
MOVB
```

### 5.2.3 OFSET

O código OFSET indica o deslocamento de um elemento do tipo registro(RECORD) a partir do endereço inicial do registro. O cálculo de endereço do tipo OFSET é feito em dois passos: Carregar o endereço inicial do registro no BX, e somar o deslocamento do subcampo para o BX. Se o deslocamento estiver menor do que 2, então a instrução INC BX é usada o vez da instrução ADD BX.

Exemplo:

```
PROGRAM OFSET;
TYPE t = RECORD
          a : boolean;
```

```

        b : char
    END;
VAR      v : ARRAY[1..10] OF t;
        i : integer;
BEGIN
    v[i].b:='A'
END.
```

Arvore de sintaxe da tribuicao v[i].b:='A';

```

STOL
    OFFSET size : 1  dsp : 1
    INDEX size : 2
    VARBL v
    ISUB
    VARBL i
    LITER 1
    LITER 1
```

Codigo gerado

```

MOV BX , @ ('Endereco de v' menos tres)
MOV AX , i
SHL AX , 1 ; AX <= AX * 2
ADD BX , AX
INC BX      ; BX <= BX + 1 deslocamento de b
MOV BYTE 0[BX] , 'A'
```

#### 5.2.4 INDEX

O codigo INDEX possui dois argumentos:

1. ARG[1] : Endereco inicial de indexacao.
2. ARG[2] : Expressao de deslocamento do inicio.

Alem disso, o codigo INDEX possui a informacao de tamanho de cada elemento (em numero de byte) de cada INDEX. A maneira de calcular o endereco de INDEX e' seguinte:

1. Calcular o endereco inicial de indexacao.
2. Calcular o valor da expressao no ARG[2]
3. Multiplica o valor calculado por o tamanho de elemento e somar cujo valor para o endereco inicial de indecacao anteriormente calculado.

Existe um detalhe neste caso. O endereço inicial de endxacao é calculado e armazenado no registrador BX. Pode acontecer que o registrador BX é usado durante o calculo de expressao no ARG[2]. O Passo 2 verifica se BX é usado durante este calculo. Se BX é usado, entao o Passo 2 salva o valor do BX e restaura depois de calculo de expressao.

Exemplo:

```
PROGRAM index;
VAR      i , j : integer;
         v : ARRAY[1..5,1..10] OF integer;
BEGIN
  v[i,j]:=10
END.
```

Arvore montada para a atribuicao v[i,j]:=10

```
-----
STDL
INDEX size : 2    disp : 2
INDEX size : 20   disp : 10
  VARBL v
  ISUB
    VARBL i
    LITER 1
  ISUB
    VARBL j
    LITER 1
  LITER 10
```

Codigo gerado para a atrubuicao v[i,j]:=10

```
-----
MOV BX , 0C 'Endereco de v' menos 20)
           ; 0C significa immedioato
MOV AX , i
MOV SI , 20
MUL AX , SI
ADD BX , AX
MOV AX , j
DEC AX
SHL AX , 1          ; AX <= AX * 2
ADD BX , AX
MOV WORD 0[BX] , 10
```

Note que os primeiros cinco instrucoes geradas sao equivalentes à seguinte sequencia de instrucoes:

```
MOV BX , $ Endereco de v
```

### 5.2.2 RDATA

O Passo 1 calcula o espaço de memória necessário para os constantes do programa inteiro. O endereço é calculado através do endereço inicial da área reservada para os constantes(@DATABASE) e o deslocamento da constante.

Exemplo:

```
PROGRAM RUATA;
CONST str = 'ABC';
VAR v : ARRAY[1..3] OF char;
BEGIN
  v:=str
END.
```

Arvore montada para v:=str

```
-----  
MOVEM size : 3  
VARBL v  
RDATA str
```

Código gerado

```
-----  
MOV DI , @ (Endereço de v)  
; @ significa imediato  
MOV SI , @ (Endereço de str)  
MOV CX , 3  
REP  
MOVE
```

### 5.2.3 DFSET

O código DFSET indica o deslocamento de um elemento do tipo registro(RECORD) a partir do endereço inicial do registro. O cálculo de endereço do tipo DFSET é feito em dois passos: Carregar o endereço inicial do registro no BX, e somar o deslocamento do subcampo para o BX. Se o deslocamento estiver menor do que 2, então a instrução INC BX é usada em vez da instrução ADD BX.

Exemplo:

```
PROGRAM DFSET;
TYPE t = RECORD
          a : boolean;
```

```

        b : char
    END;
VAR      v : ARRAY[1..10] OF t;
        i : integer;
BEGIN
    v[i].b:='A'
END.
```

Arvore de sintaxe da tribuicao v[i].b:='A';

```

STCL
  OFFSET size : 1  dsp : 1
  INDEX size : 2
    VARBL v
    ISUB
      VARBL i
      LITER 1
    LITER 1
```

Codigo gerado

```

MOV BX , @ ('Endereco de v' menos tres)
MOV AX , i
SHL AX , 1 ; AX <= AX * 2
ADD BX , AX
INC BX ; BX <= BX + 1 deslocamento de b
MOV BYTE 0[BX] , 'A'
```

#### 5.2.4 INDEX

O codigo INDEX possui dois argumentos:

1. ARG[1] : Endereco inicial de indexacao.
2. ARG[2] : Expressao de deslocamento do inicio.

Alem disso, o codigo INDEX possui a informacao de tamanho de cada elemento (em numero de byte) de cada INDEX. A maneira de calcular o endereco de INDEX e' seguinte:

1. Calcular o endereco inicial de indexacao.
2. Calcular o valor de expressao no ARG[2]
3. Multiplicar o valor calculado por o tamanho de elemento e somar cujo valor para o endereco inicial de indecacao anteriormente calculado.

```

MOV AX , 1
DEC AX
MOV SI , 20
MUL AX , SI
ADD BX , AX

```

O Passo 2 obtém a parte calculável em tempo de compilação.

### 5.2.5 INDIR

O código INDIR possui apenas um argumento. O argumento indica o endereço da variável que está apontando. Este código possui o deslocamento de campo que está indicado dentro de registro(RECORD).

Exemplo:

```

PROGRAM indir;
TYPE      t = RECORD
            a : boolean;
            b : char
          END;
VAR       p : at;
BEGIN
  p^.b := 'A'
END.

```

Árvore de sintaxe equivalente

-----

```

STOL
  INDIR size : 1 dsp : 1
    VARBL p
    LITER 'A'

```

Código gerado

-----

```

MOV BX , p
MOV BX , 0[BX] ; Indireção
INC BX          ; Deslocamento de b
MOV BYTE 0[BX] , 'A'

```

### 5.3 O PROBLEMA DA GERACAO DE CODIGO PARA DESVIO CONDICIONAL

Existem dois tipos de desvios: Um é desvio para um endereço absoluto. Outro é para um endereço relativo(deslocamento) ao endereço de instrução de desvio. A vantagem de desvio com deslocamento é que o código fica auto-relocável. A maioria das instruções de desvio do INTEL 8088 é deste tipo.

Todas as instruções de desvios condicionais tem apenas um byte de deslocamento. Quando o deslocamento de desvio for maior do que um byte não podemos gerar o código de desvio condicional diretamente, precisamos gerar o código da seguinte maneira:

Exemplo :

```
J<cond> LA
...
...
LA:
(CASO 1 Código ideal)
```

```
J<not cond> L1
JMP LA
L1: ...
...
LA:
(CASO 2)
```

```
J<not cond> b + 5
JMPL LA
...
...
LA:
(CASO 3)
```

No caso 1 do exemplo, o custo de memória para desvio condicional é apenas 2 bytes. Porem para poder gerar este código, precisamos ter certeza de que o deslocamento é menor do que 2 bytes. Para saber o deslocamento de desvio condicional, precisamos calcular quantos bytes são necessários para gerar o trecho do código entre J<cond> LA e LA:. Além do mais, se tiver várias instruções de desvio condicionais encaixados, precisamos calcular os deslocamentos recursivamente, de dentro para fora. Isto significa que precisamos gerar o código duas vezes, para gerar códigos de desvio condicionais otimizados. O "overhead" da otimização deste tipo seria muito grande. Decidimos desistir deste tipo de otimização.

O Caso 2 tem um problema tambem. Para cada desvio condicional, precisamos de dois rotulos e isto daria uma carga pesada para o montador do INTEL 8088. A maneira de evitar o uso de rotulo adicional, como o Caso 2, seria gerar o codigo de desvio condicional de deslocamento de valor fixo como no Caso 4. A nova instrucao JMPL esta' introduzida no Caso 3 por seguinte razao: O INTEL 8088 possui dois tipos de desvios incondicionais: o deslocamento de um byte e o deslocamento de dois bytes. A decisao de deslocamento de um ou dois bytes e' tomada pelo montador. Quando o deslocamento for menor do que de 2 bytes, o montador gera o codigo para desvio incondicional de um byte apenas. Portanto, neste caso a sequencia de codigos no exemplo seguinte nao funcionaria corretamente.

```
J<not cond> $+5  
JMP LA
```

Como nao sabemos o tamanho de deslocamento no momento de geracao de codigo para desvio condicional, precisamos forcar a geracao de um desvio com deslocamento de 2 bytes. Isto e' o que faz a instrucao JMPL. Ao invez de gerar codigo para desvio condicional de dois bytes diretamente, gastamos 5 bytes para cada instrucao deste tipo. Como isto ocorre frequentemente, e.g. comandos IF, WHILE, REPEAT, LOOP, FOR, etc. A perda de memoria por causa deste problema da arquitetura do INTEL 8088 nao e' insignificante.

## 5.4 OTIMIZACOES MISCELANEAS

Todas as otimizacoes sao do tipo local. Algumas sao feitas no nivel da arvore de sintaxe construida pelo Passo 2 e algumas sao feitas utilizando as caracteristicas de hardware do INTEL 8088.

### 1. Modificacoes da arvore se sintaxe Exemplos

1.  $\langle \text{exp} \rangle + 1 \Rightarrow \text{INC}(\langle \text{exp} \rangle)$
2.  $\langle \text{exp} \rangle - 1 \Rightarrow \text{DEC}(\langle \text{exp} \rangle)$
3.  $\langle \text{exp} \rangle * \langle \text{exp} \rangle = \text{SQR}(\langle \text{exp} \rangle)$   
quando as duas expressoes sao identicas.
4.  $\langle \text{exp} \rangle + 0 \Rightarrow \langle \text{exp} \rangle$
5.  $\langle \text{exp} \rangle * 1 \Rightarrow \langle \text{exp} \rangle$
6.  $\langle \text{exp} \rangle * 0 \Rightarrow 0$
7.  $\text{NOT } \langle \text{cond} \rangle \Rightarrow \langle \text{cond inversa} \rangle$   
e.g.  $\text{NOT } (i < j) \Rightarrow i \geq j$   
Esta otimizacao e' bastante util especialmente para geracao de codigo para LOOP do tipo WHILE, porque a condicao de saida do LOOP deste tipo e' sempre contraria a condicao escrita em Pascal. O seguinte exemplo mostra um caso tipico deste. Note que a expressao  $\text{NOT } (\text{NOT } \langle \text{cond} \rangle)$  e' modificada para  $\langle \text{cond} \rangle$ .

```

WHILE NOT ( i < j ) DO
BEGIN
  ...
  ...
END;

L1:
MOV AX , i
CMP AX , j
JL L2
< A parte do comando composto >
JMP L1
L2:

```

8. Calculo de partes fixas em indexacao  
Como a geracao de codigo para indexacao fica bastante cara em termos de memoria, seria desejavel calcular as partes calculaveis da indexacao durante a compilacao. O Passo 2 verifica as partes constantes de indexacao e faz as partes calculaveis antes da geracao de codigo final. Neste momento, a

arvore de sintaxe é modificada. Se todos os indices de indexacao forem constantes, seu endereco sao tratado como se fosse de uma variavel simples. Todos indices de matrizes com valor calculavel durante compilacao sao aproveitados na geracao de codigo. O seguinte exemplo mostra um caso de otimizacao de codigo deste tipo em combinacao a otimizacao de codigo para atribuicoes.

Exemplos :

```
a[2,5] := a[2,5] - 1
```

```
DEC a[2,5]
```

```
a[2,5] := 10
```

```
MOV a[2,5], 10
```

Onde o endereco de a[2,5] é calculado pelo Passo 2

#### 9. Calculo de endereco do tipo OFFSET(RECORD)

Quanto ao endereco de um subcampo do tipo registro simples, podemos calcular seu endereco durante compilacao.

Exemplo :

```
x : RECORD
      a : integer;
      b : boolean;
      c : char
END;
```

Note que os enderecos de subcampos a,b e c sao calculaveis durante compilacao. O passo 1 calcula os enderecos de cada subcampo e cada subcampo é tratado como se fosse variavel simples.

#### 2. Aproveitamento de hardware do INTEL 8088

1. Ao inves de multiplicar um valor que esta' num registrador por 2, utiliza a instrucao SHL para registrador. Seria muito util se este tipo de otimizacao fosse aplicavel para multiplicacoes por 4, 8, 16 etc. ou divisoes por 4, 8, etc. Infelizmente, quando este codigo SHL ou SHR estiver aplicado, a flag de overflow do INTEL nao indica o resultado corretamente, o que causaria problema de RUNTIME CHECK do tipo overflow. Por esta razao

desistimos de aplicar esta otimizacao para os casos extendidos. Sendo este tipo de otimizacao muito especifico, isto é bastante util para geracao de codigo para indexacao. Variaveis ou tipos de matriz ou vetor do tipo inteiro sao comuns em Pascal. Neste caso a multiplicacao por 2 é necessaria.

2. O INTEL 8088 possui instrucoes de PUSH e POP da seguinte forma:

```
PUSH e.e (Endereco efetivo)
POP e.e
```

Ao gerar codigo para passagem de parametros, se os parametros estiverem variavel ou parametro simples as instrucoes PUSH e POP podem ser gerados diretamente. Quando tipo de parametros estiverem complexos, precisamos carregar seu enderecos ou valores de expressao nos registradores BX ou AX primeiro.

3. Ao inves de somar um valor que esta' num registrador por 1 ou 2, utiliza a instrucao INC. Este tipo de otimizacao tambem é bastante especifico, porem, é bastante util na pratica. Esta otimizacao nao é aplicavel para apenas geracao de codigo para expressoes, mas muito util na geraco de codigo para enderecos.

**Exemplo :**

```
x : ARRAY[1..10] OF RECORD
    a : char;
    b : boolean;
    ...
END;

...
x[i].b:=true;

MOV AX, i
DEC AX
SHL AX, 1
LEA BX, x
ADD BX, AX
INC BX      ; BX <= BX + 1
MOV 0[BX], 1 ; true
```

4. Ao inves de somar ou subtrair o valor do registrador SP para alocar ou desalocar a memoria(STACK) na entrada ou saida de uma rotina, cujo valor estiver menor ou igual a 6. Suponhamos que uma rotina tiver variaveis locais de 4 bytes em

total, precisamos alocar 4 bytes na pilha na entrada e desalocar 4 bytes na saida.

Exemplo :

```
SUB  SP , 4 ; <= alocacao
ADD  SP , 4 ; <= desalocacao

PUSH AX
PUSH AX      ; <= alocacao
POP  AX
POP  AX      ; <= desalocacao
```

A dealocacao de memoria na pilha nao e' feita na saida de rotina apenas, mas e' feita na saida dos comando FUR e WITH tambem. Apesar do numero de instrucoes geradas ser maior do que o primeiro caso, o tamanho de codigo gerado sera menor e a execucao sera mais rapida. Devido ao problema de alinhamento do PDP 11, o numero de bytes alocados para variaveis locais e' sempre ajustado para ser par.

5. Utilizacao da instrucao XLAT em indexacao.  
XLAT do INTEL 8088 e' uma instrucao muito interessante para geracao de codigo para indexacao. O funcionamento da XLAT e' o seguinte:

```
AL <= [ BX + AL ]
```

Note que esta instrucao e' aplicavel quando um valor indexado de vetor (apenas uma dimensao) cujo tipo de limites(escalar) for de um byte apenas.

```
ARRAYE tipo1 ] OF tipo2
```

Os dois tipos tipo1 e tipo2 devem estar representado em um byte para aplicar esta instrucao.

Exemplo :

```
x : ARRAYE char ] OF boolean;
ch : char;
b : boolean;

b:=x[ch];
```

```
MOV  AL , ch
LEA  BX , x
XLAT
MOV  b , AL
```

## 5.5 OTIMIZACAO PEEPHOLE

Otimizacao peephole é um tipo de otimizacao local. A palavra peephole é derivada do fato de que este tipo de otimizacao utiliza apenas uma visao restrita do codigo gerado. Um exemplo tipico desta otimizacao esta' no seguinte exemplo:

Exemplo :

```
x:=y;
z:=x+z
      MOV AX , y
      MOV x , AX
      MOV AX , x <= instrucao superflua
      ADD AX , z
      MOV z , AX
```

Para descobrir este tipo de instrucoes superfluas, basta verificar se uma instrucao antes da MOV reg , x é do tipo MOV x , reg.

Como o nosso gerador de codigo trabalha com arvores de expressoes, podemos aplicar esta otimizacao no sentido mais geral do que esse. Na otimizacao peephole convencional, verificamos uma instrucao antes da instrucao atualmente sendo gerada. Isto significa que nos verificamos o valor sendo armazenado num registrador antes de gerar o codigo da instrucao do tipo MOV reg , x. Como o Passo 2 trabalha com arvore na geracao de codigo, podemos guardar a informacao de valores guardados nos registradores de uma forma de arvore tambem. Isto facilita a otimizacao de codigo de visao bem maior do que da otimizacao original.

No passo 2 existem duas variaveis globais AXpointer e BXpointer do tipo apontador de arvore de expressao que apontam a arvore de valores de cada registrador atualmente guardado durante geracao de codigo.

Exemplo :

```
i:=j + 1;
a[i]:=10 + a[i] * 5
      MOV AX , j
      INC AX
      MOV i , AX
      MOV BX , a
      ( MOV AX , i )
      SHL AX , 1 ; AX <= AX * 2
      ADD BX , AX
      ( PUSH BX )
      ( LEA BX , a )
      ( MOV AX , i )
```

```

        ( SHL AX , 1 )
        ( ADD BX , AX )
MOV AX , 0[BX]
MOV BX , 5
IMUL BX
ADD AX , 10
        ( POP BX )
MOV 0[BX] , AX

```

NOTE : As instrucoes entre parenteses sao omitidas

A seguinte tabela mostra a frequencia das otimizacoes aplicadas do tipo peephole generalizado, para geracao de codigo de tres programas descritos secao 5.6.

Frequencia de otimizacoes de peephole

	programa 1	programa 2	programa 3	
AX	63	25	3	
BX	40	12	0	

Um detalhe importante desta otimizacao e' que os valores carregados nos registradores podem ser destruidos se houver algum tipo de desvio envolvido antes da instrucao omitida. O seguinte exemplo mostra o caso em que esta otimizacao nao e' aplicavel.

Exemplo :

```

x:=y;
10 : z:=x + y;

```

A otimizacao peephole e' aplicavel dentro do bloco basico. Bloco Basico e' uma sequencia de instrucoes maximal em que para quaisquer nao existe instrucoes de desvio ou referencia de endereco de desvio. O passo 2 zera os valores de variaveis AXpointer e BXpointer quando instrucao de desvio e' gerada ou encontrou uma referencia de endereco de

desvio.

O passo 2 pode otimizar a expressao de atribuicao antes da geracao de codigo para verificar se este tipo de otimizacao pode ser feita.

Exemplo :

```
a[i]:=y;  
z:=w + a[i]
```

A expressao w + a[i] e' modificada para a[i] + w antes da geracao de codigo.

Outro exemplo da otimizacao peephole e' otimizacao de codigo para uma expressao quando seu valor e' calculavel durante o tempo de compilacao.

Exemplo

```
x:=2.0 * 3.14159265/360.0 + x;  
IF x < 0.0 THEN ...
```

Como o valor da subexpressao  $2.0 * 3.14159265/360.0$  e' calculavel durante o tempo de compilacao, nao precisamos gerar o codigo para calcular o valor desta subexpressao. Este tipo de otimizacao e' feita pelo proprio passo 1 do compilador nbs. Se uma expressao e' calculavel durante o tempo de compilacao, seu valor e' automaticamente calculado antes de gerar o codigo-p para o passo 2.

Outro tipo de otimizacao comum, considerada como otimizacao peephole, e' a otimizacao de multiplos desvios incondicionais.

Exemplo :

```
GOTO L1  
...  
...  
L1 : GOTO L2  
...  
...  
L2 : ...
```

Este tipo de otimizacao apresenta mais vantagens em termos de tempo de execucao do que em termos de tamanho de codigo gerado e nao foi implementado [McKe65].

## 5.6 ATRIBUICAO

Ha' tres tipos de Código-P para atribuicoes no Pascal NBS:

1. STCL : Para atribuicao de uma variavel representada por um byte ou dois bytes. (e.g. integer, char, boolean, scalar )
2. STCR : Para atribuicao de valores do tipo real. Como o tipo real e' implementado por dois bytes no nosso compilador, o tratamento do STCR fica identico ao tratamento do Código-p STJL .
3. MOVEM : Para atribuicao de variavel cuja representacao interna e' maior do que 2 bytes. Este codigo e' usado para atribuicao de uma variavel ou um parametro do tipo vetor ou do tipo registro.

### [ SICL ]

O Código-P STCL possui dois argumentos:

ARG[1] : Apontador da arvore de endereco  
ARG[2] : Apontador da arvore de expressao

O funcionamento canonico deste Código seria o seguinte:

1. empilhar o endereco que esta' representado no ARG[1] para TOPO da pilha.
2. Empilhar o valor da expressao que esta' representada no ARG[2].
3. Executar a seguinte sequencia de operacao sobre pilha:

1. [ pilha[TOPO] ] <= pilha[top] - 1
2. TOPO <= TOPO - 1

Observe que a ordem de empilhar os dois operandos deste código nao e' irrelevante por causa de efeitos colaterais. Em certos casos a troca de ordem de calculo dos parametros e' interessante para otimizacao de código. O problema de efeitos colaterais ocorre quando o endereco de atribuicao e' representado por indice de vetores ou matrizes, ou apontadores.

Como explicado anteriormente, os enderecos sao carregados no registrador BX e o valor de expressao e' carregado no registrador AX. Em certos casos, o uso de registrador BX e' requerido para o calculo de expressao. Quando o calculo de endereco deve ser feito antes do calculo de expressao e o calculo desta expressao pode usar o registrador BX, precisamos salvar o valor no registrador BX antes de calculo da expressao e restaura-lo depois.

No Passo 2, atribuicao do tipo STBL sao divididas em 8 casos para aproveitar ao maximo os recursos do microprocessador INTEL 8088.

Na geracao de codigo para expressao, como uma operacao binaria, se o segundo operando for um valor literal por exemplo, este valor nao precisa ser carregado no registrador. Analogamente no caso de geracao de codigo para atribuicoes, se o valor de atribuicao estiver um valor literal, este valor nao precisa ser carregado no registrador AX.

Existem dois tipos de enderecos de atribuicao;

1. Endereco simples :

Endereco de uma variavel simples ou parametro simples. Neste caso, nao precisamos carregar o endereco no registrador BX.

2. Endereco complexo :

Endereco que nao e' simples.

Existem dois tipos de expressoes de atribuicao;

1. expressao simples :

Expressao que e' valor literal.

Neste caso, nao precisamos carregar o valor da expressao no registrador Ax..

2. Expressao complexa :

Expressao que nao e' simples.

Essa combinacao de tipos de enderecos e expressoes, leva a 4 tipos diferentes de atribuicao.

	expressao simples	Expressao complexa
Endereco!	ATR 1	ATR 2
Simples !		
Endereco!		
complexo!	ATR 3	ATR 4
!	!	!

Exemplo :

```

ATR 1 : i:=20 , b:=true etc.
ATR 2 : i:=j+k
ATR 3 : a[i]:=5
ATR 4 : a[i]:=j+k

```

Os tipos de atribuicoes ATR 2 e ATR 4 sao divididos em tres tipos cada.

## AIR 2

### 1. AIR 21 :

<ende. simpl.> := <ende. simpl.> OP liter  
Onde os dois enderecos sao identicos.

Exemplos :            i:=i+10  
                      i:=-i  
                      ch:=succ(ch)

<ende. simpl.> := OP <ende. simpl.>

Exemplos :            i:=pred(i)  
                      i:= - i

### 2. AIR 22 :

<ende. simpl.> := <ende. simpl.> OP <expr.  
compl.>

Onde os dois enderecos sao identicos.

Exemplo :            i:=i - a[i]\*j

### 3. AIR 23 :

Caso do ATR 2 que nao pertence aos casos ATR 21 e ATR 22

Note que o compilador é suficientemente esperto para detectar a atribuicao  $i := 10 + i$ , por exemplo, é do tipo ATR 21. Otimizacao da expressao da atribuicao é feita antes de determinacao do tipo de atribuicao tambem.

Exemplo :

```
a[5]:=a[5]+1
```

Como o indice do vetor de a é constante, o endereco de a[5] pode ser calculado em tempo de compilacao. Este tipo de otimizacao é feita no Passo 2. Esta atribuicao não é do tipo ATR 42 mas ATR 21. Um caso mais interessante é atribuicoes do tipo:

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

O compilador modifica a expressao  $i + 1$  para succ(i) antes da determinacao do tipo e finalmente gera o codigo:

```
inc i
```

#### AIR 4

##### 1. AIR 41 :

`<end. compl.> := <expr. compl.> CP liter`

Onde os dois enderecos sao identicos.

Exemplo : `a[i]:= not a[i]`

##### 2. AIR 42 :

`<ende. compl.> := <ende. compl.> CP <expr. compl>`

Onde os dois enderecos sao identicos.

Exemplo : `a[i]:= a[i] + i + j`

##### 3. AIR 43 :

Caso de ATR 4 que nao pertence aos casos ATR 41 e ATR 42. Este caso é o caso pior porque precisamos carregar os enderecos e o valore da expressao de atribuicao nos registradores.

Os casos ATR 21, ATR 22, ATR 41, ATR 42 sao os casos em que podemos aproveitar os recursos do INTEL 8088. Para verificar a identidade de dois enderecos representados em forma de arvore, existe uma funcao booleana SUBTREEMATCH(r1,r2 : ptr):boolean que devolve o valor TRUE se as duas arvores representadas por r1 e r2 sao identicas.

Uma observacao importante na divisao de casos em atribuicoes é que os casos ATR 1, ATR 2, e ATR 3 sao livres do problema de efeitos colaterais em relacoes aos endereco e valor da expressao de atribuicao. Especialmente quando o endereco de atribuicao for simples, nao precisamos carregar o endereco no registrador BX antes do calculo da expressao.

A geracao de codigo para cada tipo de atribuicao é a seguinte:

1. ATR 1 : Usar a instrucao do tipo  
`MOV <ende.>, liter`  
 Neste caso nem o endereco ou valor da expressao precisa ser carregado nos registradores AX e BX.  
 Exemplo : `i:=10;` `MOV i, 10`
2. ATR 21 : Usar instrucoes do tipo  
`OP <ende. simpl.>, liter`  
 Onde OP pode ser ADD, SUB ou  
`OP <ende. simpl.>`  
 Onde OP pode ser INC, DEC, NEG  
 Um detalhe importante é que operacoes de multiplicacao e divisao nao podem ser aplicadas para este tipo devido ao HARDWARE da maquina.
- Exemplo :  
`i:= i-7` `SUB i, 7`  
`i:= - i` `NEG i`
3. ATR 22 :  
 Primeiramente carregar o valor da subexpressao da expressao da atribuicao no registrador AX e usar instrucoes do tipo:  
`OP <ende. simpl.>, AX`  
 Onde OP podem ser ADD, SUB  
 Exemplo :  
`i:= i + i * j`  
`MOV AX, i`  
`IMUL AX, j`  
`ADD i, AX`
4. ATR 41 :  
 A ideia basica de geracao de codigo é semelhante aos casos de ATR 21, ATR 22, ATR 23. A unica diferenca entre os casos de ATR 21, ATR 22, ATR 23 e os casos de ATR 41, ATR 42 e ATR 43 é o endereco de atribuicao é carregado no registrador BX primeiramente.  
 Carregar o endereco de atribuicao no BX primeiro.  
 Usar as instrucoes do seguinte tipo:  
`OP [BX], liter`  
 Onde OP podem ser ADD, SUB ou  
`OP [BX]`  
 Onde OP pode ser INC, DEC, NEG  
 Exemplo :  
`a[i]:=a[i] + 10;`  
`LEA BX, a`  
`MOV AX, i`  
`DEC AX`  
`LSH AX, 1`  
`ADD BX, AX`

```
ADD [BX] , 10
```

## 5. ATR 42 :

Carregar o endereco comum da atribuicao no registrador BX primeiro e carregar o valor da subexpressao da atribuicao no registrador AX e gerar o codigo do tipo :

```
OP [BX] , AX
```

Onde OP pode ser ADD ou SUB

Exemplo :

```
a[i]:=a[i] + i + j
      LEA BX , a
      MOV AX , i
      DEC AX
      LSH AX , 1
      ADD BX , AX
      MOV AX , i
      ADD AX , j
      ADD [BX] , AX
```

## 6. ATR 43:

Este e' o pior caso na geracao de codigo para atribuicoes. Precisamos carregar o endereco da atribuicao no registrador BX e carregar o valor de expressao no registrador AX e usar a instrucao:

```
MOV [BX] , AX
```

Exemplo :

```
a[i]:=i+j
      LEA BX , a
      MOV AX , i
      DEC AX
      SHL AX , 1
      ADD BX , AX
      MOV AX , i
      ADD AX , j
      MOV [BX] , AX
```

Um ultimo detalhe sobre geracao de codigo no caso da linguagem Pascal e' o ajuste do tamanho de valores na atribuicao.

Exemplo :

```
i:=ORD(ch - 40b)
```

Neste caso, a variavel ch esta' representada em um byte enquanto a variavel i esta' representada em dois bytes. Portanto precisamos ajustar o tamanho do dado antes de executar a atribuicao.

O codigo gerado pelo Passo 2 e' seguinte :

```
MOV AL , ch
SUB AL , 40b
XOR AH , Ah      ; zerar o valor do AL
MOV WORD i , AX
```

O Passo 2 ajusta o tamanho de operandos na instrucao de MOV dependendo do tamanho de variavel a ser atribuida. Portanto quando o tamanho de variavel de destino da atribuicao for menor do que o tamanho de valor de expressao, nao ha' problema de reajuste de tamanho, pois o valor de expressao e' ajustado automaticamente.

A tabela abaixo mostra que os casos ATR 22, ATR 41, ATR 42 sao bem menos frequentes do que os outros. Observamos que o caso ATR 1 e' muito frequente apesar de que este tipo de atribuicao e' um caso especifico. A otimizacao feita sobre atribuicoes do tipo ATR 1 e' muito significante. Os programas 2 e 3 foram escritos pelo autor.

Programa 1 :

Passo 1 do compilador NBS original.( 4500 linhas )

Programa 2 :

Interpretador LOGO ( 3000 linhas )

Esse programa e' basicamente um interpretador BASIC com chamada recursiva de procedimentos com parametros e recursos graficos.

Programa 3 :

Interpretador LISP ( 800 linhas )

Este programa implementa apenas recursos basicos da LISP.

## Frequencia de casos em atribucoes

	Programa 1	Programa 2	Programa 3	
ATR 1	306 (30.1 %)	173 (27.8 %)	46 (34.1 %)	
ATR 21	77 (7.7 %)	44 (7.1 %)	5 (3.7 %)	
ATR 22	15 (1.5 %)	1 (0.2 %)	0 (0.0 %)	
ATR 23	335 (33.4 %)	229 (36.8 %)	69 (51.1 %)	
ATR 3	126 (12.6 %)	48 (7.7 %)	2 (1.5 %)	
ATR 41	1 (0.1 %)	0 (0.0 %)	0 (0.0 %)	
ATR 42	2 (0.2 %)	1 (0.2 %)	0 (0.0 %)	
ATR 43	140 (14.0 %)	126 (20.3 %)	13 (9.6 %)	
TOTAL	1002	622	135	

## E MOVEM J

Este codigo-P possui tres informacoes:

1. DISP : Numero de bytes para transferir
2. ARG[1] : Apontador de endereco de fonte de transferencia
3. ARG[2] : Apontador de endereco de destino de transferencia

Existe uma instrucao muito conveniente para este codigo: MOV8. Esta instrucao transfere o numero de bytes que esta' carregado no registrador CX a partir do endereco que esta' carregado no registrador SI para o endereco que esta' carregado no registrador DI(Block Transfer).

Exemplo:

```
VAR      a,b : ARRAY[1..10] OF integer;
a:=b;
```

```
LEA DI , a
LEA SI , b
MOV CX , 20
REP
MOV8
```

O numero de bytes para transferencia que e' carregado no registrador CX deve ser logo antes da instrucao MOV8, porque o registrador CX pode ser usado durante calculos de enderecos para carregar no AX e CX. Neste caso particular o numero de byte para transferir e' sempre definido durante compilacao por virtude da definicao de Pascal.  
p; Analogamente no caso de geracao de codigo para o Código-P STOL, precisamos carregar o valor do registrador DI devido ao problema de efeitos colaterais e verificar se o valor carregado no DI e' destruido durante o calculo de endereco para carregar no registrador SI. Se o valor for destruido, precisamos salvar o conteudo no registrador DI antes de calcular o endereco para carregar no registrador DI e restaura-lo depois.

### 5.7 COMANDO IF

Nao ha' muito para otimizar na geracao de codigo do comando IF. O comando possui duas formas :

1. IF <exp. booleana> THEN <comando>;
2. IF <exp. booleana> THEN <comando 1>  
ELSE <comando 2>

A geracao de codigo para cada forma seria seguinte :  
Calcula em AX o valor da expressao booleana.

Existem dois tipos de otimizacoes feitas na geracao de codigo para este comando.

1. Omissao de carregamento de valor booleano no AX.  
A maneira mais simples de gerar codigo para o comando IF seria, primeiramente, calcular o valor da expressao booleana no registrador AX e testar a paridade do valor no AX (convencionalmente o valor FALSE esta' representado 0 e o valor TRUE esta' representado 1). Porem, esta maneira nao seria eficiente no seguinte caso:

Exemplo :

```
IF i < j THEN <comando>
```

Codigo gerado da maneira usual

```
=====
```

```
MOV AX , i
CMP AX , j
MOV AX , 0
JGE $+3
INC AX
JL L1
<codigo gerado para o comando>
L1:
```

Codigo gerado mais eficiente. Omitir o carregamento do valor booleano em AX.

```
=====
```

```
MOV AX , i
CMP AX , j
JL $+5
```

```
JMP L1  
<codigo gerado para o comando>  
L1:
```

Note que este tipo de geracao nao e' sempre possivel. Quando a expressao booleana for mais complexa, como "b and (i < j)", precisamos carregar o valor da subexpressao (i < j) no AX para calcular o valor da expressao booleana inteira. O gerador de codigo detecta os casos de expressoes booleanas complexas e gera o codigo correspondente.

2. Geracao de codigo condicional quando o valor de expressao e' calculavel durante a compilacao. As vezes o valor da expressao booleana e' calculavel durante a compilacao como no exemplo abaixo :

Exemplo :

```
CONST debug = true;  
IF debug THEN <comando 1>  
    ELSE <comando 2>
```

Neste caso, o compilador gera codigo para o comando1 apenas.

## 5.8 COMANDO CASE

Existem dois metodos basicos para implementar o comando case:

### 5.8.1 Utilizar Uma Tabela De Saltos

A tecnica usada e' simples e a geracao de codigo e' feita em quatro partes:

1. Calcular o valor de expressao do comando case.
2. Verificar o valor calculado com os valores inferior e superior dos valores dos seletores, e subtrair do valor calculado o valor inferior de seletores. Como os valores de seletores do comando case sao constantes de acordo a definicao do Pascal, os valores inferior e superior de seletores sao calculaveis durante a compilacao. O endereco de salto na tabela de saltos tambem deve ser calculado.
3. Gerar a tabela de saltos
4. Gerar codigo para cada subcomando do comando CASE.

Exemplo :

```
CASE ch OF
  'a', 'b' : <comando1>
  'd'        : <comando2>
END

;Calcular o valor da expressao
MOV AL , ch

;Testar o valor com limites e
;Calcular o endereco de salto
CMP AL , 'a' ; limite inferior
JL L3
CMP AL , 'd' ; limite superior
JG L3
SUB AX , 65 ;ASCII para 'a'
SHL AX , 1 ;AX<=AX * 2
ADD AX , TAB ; imediato
XCHG AX , BX ;para indirecao
MOV AX , 0[BX]
JMP AX

;tabela de salto
TAB: DW L1 ; 'a'
```

```

DW L1 ; 'b'
DW L3 ; 'c'
DW L2 ; 'd'

;subcomandos
L1: <comando1>
    JMP L3
L2: <comando2>
L3:

```

Certamente este metodo é muito eficiente em termos de tempo de execucao. Independentemente do valor da expressao do comando case, o tempo de execucao na parte de selecao de casos é constante. Porem o tamanho da tabela é proporcional à diferenca entre os limites superior e inferior. O seguinte exemplo mostra um caso em que este metodo é indesejavel em termos de espaco de memoria.

Exemplo :

```

CASE i OF
    0 : <comando1>
    1000 : <comando2>
END

```

#### 5.8.2 Comparacao Linear Com Cada Seletor

Este metodo é ineficiente em termos de tempo de execucao, que é proporcional ao numero de seletores no comando case. Porem a geracao do codigo para o exemplo anterior seria bem melhor. O codigo gerado para o penultimo exemplo seria o seguinte:

```

MOV AL , ch
CMP AL , 'a'
JE L1
CMP AL , 'b'
JE L1
CMP AL , 'd'
JE L2
JMP L3
L1: <comando1>
    JMP L3
L2: <comando2>
L3:

```

O metodo ideal é analizar cada caso do comando case e decidir qual metodo é mais eficiente. Porem a decisao de metodo apropriado para cada caso tambem é dificil. O seguinte exemplo mostra um caso em que esta decisao nao seria tao facil.

Exemplo :

```
CASE i OF
  1,2,3,4,5,
  6,7,8,9,10 : <comando1>
  50           : <comando2>
  61,62,63,64,65,
  66,67,68,69,70 : <comando3>
END
```

O metodo adotado no passo 2 é o segundo, pois o objetivo principal do projeto nao é eficiencia em tempo de execucao, mas eficiencia em tamanho de codigo gerado. Alem disso, implementacao deste metodo é relativamente mais facil do que o primeiro metodo. Quando este metodo é adotado, seria desejavel que a sintaxe do comando case fosse extendida como mostra o seguinte exemplo.

Exemplo :

```
CASE i OF
  1..10 : <comando1>
  50     : <comando2>
  61..70: <comando3>
END
```

[Sale81], [Atki82]

## 5.9 COMANDO WHILE, REPEAT E LOOP

No Compilador Pascal NBS, os comandos; WHILE, REPEAT, e LOOP sao representados internamente como um comando LOOP. A arvore de sintaxe do comando LOOP tem numero variavel de subarvores. Cada sequencia de comandos ate' um EXIT ou END(exclusiva) corresponde a uma subarvore. Cada EXIT tambem corresponde a uma subarvore. No exemplo abaixo o codigo-P LOOP possui 3 subarvores. Para a n-esma subarvore, temos:

### 1. n e' par

O codigo da subarvore e' SEQ, i.e. codigo de comando composto. Se esta parte nao existir, entao o numero de subarvores do codigo SEQ e' zero.

### 2. n e' impar

O codigo da subarvore e' EXIT. Este codigo possui dois argumentos(subarvores); subarvore para condicao de saida do LOOP, e a subarvore para comando a executar na saida do LOOP.

Exemplo :

```
LOOP
  i:=i+1;
  EXIT IF i=j THEN i:=10;
  j:=j-1
END;
```

Arvore sintatica equivalente

```
LOOP
  SEQ
    STCL
      i
      ADD
        i
        1
    EXIT
      ICEQ
        i
        j
      STCL
        i
        10
    SEQ
      STCL
        j
      SUB
        j
        1
```

O numero de subavores do codigo LOOP e' sempre maior ou igual a tres. Repare que os comandos WHILE e REPEAT sao representados atraves do LOOP como segue:

```
REPEAT           ==>    LOOP
  <comando>
UNTIL <cond>           <comando>
                        EXIT IF <cond>
                        END
```

```
WHILE <cond> DO      ==>    LOOP
  <comando>
                        EXIT IF NOT <cond>
  <comando>
                        END
```

Note que nos casos dos comandos WHILE e REPEAT, o segundo argumento do Código-P EXIT e' sempre NULL.

Ao gerar codigo para LOOP, dois rotulos sao alocados:

RETL : O rotulo que indica o inicio do LOOP  
EXTL : O rotulo que indica a saida do LOOP

Ao gerar codigo para EXIT, um rotulo e' alocado se o segundo argumento deste codigo nao for NULL.

Codigo gerado para o exemplo anterior

```
RETL:
  INC i
  MOV AX , i
  CMP AX , j
  JE $ + 5
  JMPL SKIP1
  MOV i , 10
  JMP EXTL
SKIP1:
  DEC j
  JMP RETL
EXTL:
```

## 5.10 COMANDO FOR

O comando FOR possui cinco argumentos:

1. Variavel simples de controle
2. Expressao inicial do FOR
3. Expressao final do FOR
4. Indicacao do tipo do FOR, TO(+1) ou DOWNT0(-1)
5. Subcomando do FOR

Implementacao do Comando FOR e' simples. Este comando possui duas expressoes; a expressao inferior e a expressao superior do comando FOR.

Pela definicao do Pascal no Revised Report, a expressao superior do comando e' calculada apenas uma vez na entrada do comando. O valor da expressao superior calculado e' armazenado numa posicao temporaria da memoria. A posicao da memoria mais natural para esta finalidade seria o topo da propria pilha. No sistema de execucao atraves de pilha em Pascal, o nivel da pilha antes e depois de um comando seria sempre igual. Neste sentido 2 bytes sao alocados na entrada do comando FOR e desalocado na saida do comando FOR cujo endereco de memoria alocado e' estatico,i.e. topo da pilha. Portanto quando este valor calculado e' referido durante a execucao do comando FOR, o nivel atual da pilha e' sempre igual, o que seria um pouco diferente do caso do comando WITH. O seguinte exemplo mostra o codigo gerado pelo Passo 2.

Exemplo :

```
FOR i:=1 TO 10 DO
v[i]:=i;
```

```
MOV i , 1 ; i:= inicializacao
MOV AX , 10 ; Load exp. sup.
PUSH AX      ; Salva o valor
L1: POP AX    ; Referir o valor sup.
PUSH AX      ; Adustar o nivel
CMP AX , i ; Testa a saida
JL L2
MOV BX , v
MOV AX , i
DEC AX
SHL AX , 1
ADD BX , AX
MOV AX , i
```

```
MOV 0[BX], AX  
INC i      ; Aumentar o valor de i  
JMP L1    ; Voltar ao inicio do FOR  
L2: POP AX    ; Ajustar o nivel da pilha
```

### 5.11 COMANDO WITH

A virtude do comando WITH nao e' apenas legibilidade, mas e' eficiencia do codigo gerado. O endereco do comando WITH ,i.e. o endereco inicial do tipo registro(RECORD) especificado no inicio do comando WITH, e' calculado apenas uma vez, na entrada do comando, e seu valor e' armazenado numa posicao temporaria na memoria. O comando WITH possui dois argumentos no compilador NBS:

1. arg[1] : arvore de endereco
2. arg[2] : arvore de comando

Tres Codigos-P sao utilizados para implementar o comando WITH;

1. DIEMP  
O codigo que indica o comando WITH.
2. REEFER  
O codigo que indica o endereco do comando WITH a ser armazenado na pilha.
3. RIEMP  
O codigo que indica a referencia ao endereco armazenado na entrada

O lugar mais natural de armazenar o endereco especificado neste comando, seria a propria pilha. Neste sentido, a solucao adotada neste caso, e' identica a solucao adotada no caso do comando FOR, porem, a locacao em que este endereco e' armazenado nao e' sempre o topo da pilha ao ser referido. Lembre-se se que no caso do comando FOR, o valor da expressao de condicao de saida do comando sempre esta' no topo da pilha quando este valor e' referido. No caso do comando WITH isto nao e' necessariamente verdade. Se uma referencia para este endereco e' feita dentro do subcomando do comando WITH e se a referencia e' feita durante execucao de um comando FOR, este endereco referido nao esta' no topo da pilha.

Porem o deslocamento da pilha onde o endereco do comando WITH esta' armazenado e' estatico, quer dizer que e' calculavel durante o tempo de compilacao. O calculo de deslocamento de variavel temporaria que armazena este endereco do comando WITH na pilha e' feito pelo Passo 2 com a ajuda de informacao fornecida pelo Passo 1. O Passo 1 fornece ao Passo 2 o numero de bytes necessarios para alocar o espaco de memoria para variaveis locais da rotina corrente. Isto significa o topo de pilha atual na entrada da rotina. O deslocamento da variavel temporaria e' calculado da seguinte maneira;

## Implementacao do comando WITH

### Inicializacao de variaveis na entrada de cada rotina

1. Inicializacao do deslocamento de variavel temporaria TEMPADDR <= topo da pilha  
Esta inicializacao e' feita uma vez ao montar a arvore de sintaxe de cada rotina. Esta informacao e' fornecida pelo Passo 1.
2. Inicializar o valor do contador do comando WITH(WITHCOUNT) com zero. Esta variavel indica o nivel do encaixamento do comando WITH atual na rotina.

### Atualizacao de nivel da pilha para calcular o deslocamento de variavel temporaria

1. No momento de entrada do comando FOR decrementa TEMPADDR por 1 ou 2 conforme o tipo de variavel simples de controle do comando FOR. Note que a pilha cresce para baixo.
2. No momento de sair do comando FOR incrementa TEMPADDR por 1 ou 2 com conforme o tipo de variavel simple de comando FOR.
3. No momento de entrada do comando WITH tres coisas sao feitas;
  1. Decrementar o valor de TEMPADDR por 2(Alocacao de memoria).
  2. Incrementar o valor de WITHCOUNT por 1 e armazenar o valor de TEMPADDR na tabela WITHTABLE associado ao indice WITHCOUNT.
  3. Calcular o endereco do comando WITH que esta' representado no arg[1] e empilhar o endereco calculado na pilha.
4. No momento de saida do comando WITH tres coisas sao feitas;
  1. Incrementa o valor de TEMPADDR por 2.
  2. Decrementa o valor de WITHCOUNT.
  3. Desalocar a memoria alocada na entrada do comando WITH. Isto significa SP <= SP + 2. O Passo 2 gera o codigo POP BX pela mesma razao citada na geracao de codigo do comando FOR.

5. Cada referencia a' variavel temporaria do comando WITH  
e' associada com a identificacao do comando WITH. Logo  
cada referencia a subcampo no comando WITH atravez do  
código-P REFER e' feita atravez da tabela WITHTABLE.

O seguinte exemplo mostra um caso que o endereco do  
comando WITH nao esta' no topo da pilha ao ser referido.

exemplo :

```
TYPE
  t = RECORD
    a:integer;
    b:ARRAY[1..10] OF integer
  END;

VAR
  p : ^t;

BEGIN
  WITH p^ do
  BEGIN
    a:=10;
    FOR i:=1 TO 10 DO
      b[i]:=i
  END
END
```

## 5.12 INTERFACE DE SISTEMA DE EXECUCAO

O esquema adotado para interface de execucao pelo Passo 2 e' simples. No compilador original Pascal VBS, as duas cadeias, cadeia estatica e a cadeia dinamica sao usadas. Porem no nosso caso, usamos apenas uma cadeia dinamica. O vetor de display esta' guardado na memoria porque o INTEL 8088 nao tem numero suficiente de registradores para esta finalidade.

### 5.12.1 CHAMADA DE ROTINA

Ao chamar uma rotina, precisamos primeiramente salvar o valor do LOCAL POINTER na pilha e empilhar os parametros da rotina antes de executar a instrucao CALL. Ao voltar para a instrucao depois de CALL, precisamos restaurar o valor de LOCAL POINTER da pilha.

#### Chamada de rotina

```
PUSH BP      ; Salvar BP
<Empilhar os parametros>
CALL ROTINA
POP  BP      ; Restaurar BP
```

### 5.12.2 ENTRADA DE ROTINA

Ao entrar numa rotina, primeiramente o valor do DISPLAY do nivel corrente e' salvo e o valor de LOCAL POINTER tambem e' atualizado. Depois para verificar se a pilha estourou ou nao, uma rotina CHKMEM e' chamada. Finalmente o espaco de memoria para variaveis locais e' alocado.

#### Entrada de rotina

```
PUSH DISPLAY[nivel]
MOV  BP , SP    ; Atualizar LOCAL POINTER
SUB  SP , n     ; Alocar variaveis locais
CALL CHKMEM     ; Verificar a pilha
```

Existe um detalhe na chamada e na entrada da rotina. Quando um parametro do tipo vetor e' passado por valor, apenas seu endereco e' passado na chamada e o parametro e' tratado como se fosse uma variavel local cujo valor e' copiado na entrada. Este ato de copia e' feito logo na entrada da rotina antes da execucao do primeiro comando da rotina. A rotina CHKMEM funciona da seguinte maneira: O espaco de memoria alocado para execucao do programa e' dividido em dois tipos, a area STACK e a area HEAP. A rotina verifica o valor atual do SP(STACK) e HEAPPTR(HEAP). Se SP for menor ou igual ao valor do HEAPPTR, entao a subrotina informa que o espaco estourou e para a execucao. Esta verificacao de memoria e' feita incondicionalmente.

### 5.12.3 SAIUA DE ROTINA

Ao sair de rotina, primeiramente o espaco de memoria para variaveis locais e' dealocado. Depois o valor de DISPLAY do nivel corrente e' atualizado. Finalmente volta para a locacao onde esta rotina foi chamada. Como o INTEL 8088 possui a instrucao RET conveniente, podemos dealocar o espaco de memoria alocado para parametros ao retornar da rotina.

#### Saída de rotina

```
ADD  SP , m      ; Desalocar variaveis locais
POP  DISPLAY[nivel]
RET n            ; Retornar e desalocar parametros
```

```
*****
*
* A INTERFACE DE ENTRADA E SAIDA DE PROCEDIMENTO *
*
*****
```

ENDERECO BAIXO

A PILHA CRESCE

I I

	I	I
• • • • • . .	I=====	I
VARIAVEIS	I-----	I <--- SP
LOCAIS	I-----	I LP-4
	I-----	I LP-2
• • • • • . .	I=====	I <--- LP (BP)
	I DISPLAY NIVEL	I
	I-----	I
	I END. DE. RETORNO	I LP+2
• • • • • . .	I-----	I
PARAMETROS	I PARAM N	I LP+4
	I-----	I
	I PARAM 2	I
	I-----	I
	I PARAM 1	I
• • • • • . .	I=====	I
VAL. DE. RET.	I	I
(SG FUNCAO)	I=====	I
	I LP (BP)	I
	I-----	I

ENDERECO ALTO

## CAPITULO 6

### TESTES DO COMPILADOR

#### 6.1 TESTES DE CONFIABILIDADE DO CODIGO GERADO

As rotinas de suporte de execucao foram testadas primeiro. Todas as operacoes aritmeticas e logicas foram testadas tambem. O primeiro passo do teste do compilador foi testar cada comando com programas bastante simples. Para cada comando, varios programas simples foram compilados e executados no sistema 8088. Todos os casos de cada comando foram verificados.

O segundo passo do teste foi testar programas completos razoavelmente simples. A maioria dos programas que estao nos livros "DATA STRUCTURE + ALGORITHM = PROGRAM" e "SYSTEMATIC PROGRAMMING" do Niklaus Wirth[Wirt76],[Wirt73] que nao usam arquivos (alem do INPUT e OUTPUT) foram testados.

#### Exemplos de programas de testes

1. FUNCAO Fibonacci
2. Funcao Ackerman
3. Permutacao
4. Torre de Hanoi
5. Problema de oito rainhas
6. Ordenacao de vetor

## 7. Programas de estrutura de dados(LISTA, ARVORE BINARIA etc)

Normalmente depuracao do programa no sistema INTEL 8088 e' feita atraves dos comandos de depuracao do monitor. Porem todas as depuracoes de erros foram feitas atraves de programas proprios do compilador. Antes de testar os programas no sistema INTEL 8088, os programas foram executados no sistema DEC 10. Se as saidas nao coincidem, modificamos o programa de teste para soltar os valores intermediarios de execucao para detectar a localizacao de erro. Alema disso o comando HALT que foi adicionado no Compilador ajudou bastante a depuracao. O unico caso em que precisamos de comandos de depuracao do sistema INTEL 8088 foi o caso em que o montador montava codigo errado. Apenas quatro ou cinco erros do compilador foram detectados pelos testes maiores. As opcoes de compilacao, SELECT, TRACE, DUMPT, PRINTC (Apendice C) ajudaram bastante a depuracao do compilador.

O maior programa de teste compilado e executado foi um interpretador LISP, que implementa apenas funcoes basicas da linguagem LISP. A primeira versao do programa foi escrita para o compilador de Hamburgo e testada no sistema DEC 10 e a segunda versao foi modificada para o compilador NBS. Este programa chama muitas funcoes com parametros que sao chamadas de funcoes (o maior numero de chamada de funcoes dentro de chamada global de uma funcao e' 6). Houve apenas um erro detectado no teste deste programa.

### 6.2 TESTE DE TAMANHO DO CODIGO GERADO

O tamanho de codigo gerado pelo compilador varia muito dependendo do tipo de programa de teste. O tamanho de codigo gerado para um programa que possui bastante indexacao, por exemplo, ficaria bastante grande. Dependendo do tipo de atribuicao, o tamanno do codigo gerado varia muito tambem. Tres programas razoavelmente grandes foram testados para verificar o tamanho do codigo gerado.

1. Compilador NBS, Passo 1 original  
4000 linhas => 43 K bytes
2. Compilador PL/M  
1450 linhas => 15 K bytes
3. Interpretador LISP  
700 linhas => 8 K bytes

Os numeros incluem os codigos de subrotinas de suporte de execucao tambem. E' interessante notar que o tamanho de codigo gerado para o Passo 1 original ficou de tamano

equivalente ao gerado para o PDP 11. Considerando o fato de que o microprocessador INTEL 8088 tem menos recursos de hardware do que PDP 11, este resultado é bem satisfatório para obter o nosso objetivo principal:  
gerar código compacto.

O número de bytes de código gerado para cada linha ficou na média de oito a treze bytes.

### 6.3 TESTE DE TEMPO DE EXECUÇÃO

Apenas dois programas foram testados para esta finalidade.

1. Programa que acha número perfeito( até 8128 )  
DEC 10 - 6 min.      INTEL 8088 - 10 min
2. Programa que acha soluções de movimento de cavalo de xadrez saturando o tabuleiro de 5 x 5.  
DEC 10 - 40 min.      INTEL 8088 - 70 min

## CAPITULO 7

### PROSPECTIVAS DO PROJETO

Faltam quatro funcoes para o compilador ficar completo:

#### 1. Implementacao de E/S de arquivo em disco

Para implementar E/S no compilador precisamos de hardware e das rotinas basicas de controle de disco. Infelizmente estas rotinas ainda nao estao prontas.

#### 2. BOOTSTRAP

A E/S de discos e' indispensavel para o BOOTSTRAP. O Passo 1 original deve ser modificado para ajustar para o Passo 2 nosso que gera codigo para INTEL 8088. O Passo 2 que esta' escrito para o sistema DEC 10(Compilador de Hamburgo) deve ser reescrito para o sistema INTEL 8088(Pascal NBS). O ideal seria gerar o codigo binario diretamente, porem quando o compilador gerar codigo errado, seria bastante dificil detecta-lo.

#### 3. Recuperacao de erros

A maioria dos metodos adotados para recuperacao de erros para analise do tipo TOPDOWN usam conjuntos de simbolos cuja cardinalidade e' cerca de 60 a 70(Numero de palavras reservadas) dependendo da implementacao. Para implementar recuperacao de erros descente, precisamos no primeiro lugar implementar conjunto de cardinalidade de 64 pelo menos. O compilador Pascal Sueco que e' tambem implementado para o minicomputador PDP 11 implementa a recuperacao de erros do [wirt]. A recuperacao de erros no compilador NBS e' feita atraves de um procedimento chamado SKIP(stopsy : symboltype) que busca os simbolos ate que encontrar um simbol indicado pelo parametro. Normalmente quando um erro e' detectado, o compilador procura os simbolos ';' ou 'END'. Este tipo de recuperacao de erro mostrou-se impraticavel. Quando o compilador compilou o montador de INTEL 8088 escrito em Pascal de Hamburgo, o compilador detectou os erros muito

ineficientemente. A tabela em baixo mostra o numero de erros detectados em cada compilacao.

Numero de erros detectados		
	-----	-----
Primeira	...	45
Segunda	...	32
Terceira	...	17
Quarta	...	5
Quinta	...	145

Note que depois de cada compilacao, todos erros avisados pelo compilador foram corrigidos antes da proxima compilacao.

Para melhorar a qualidade de recuperacao de erros do compilador, algumas pequenas modificacoes foram feitas. Em primeiro lugar, precisamos explicar como a recuperacao de erros e' implementada no compilador.

Existe apenas um procedimento simples denominado SKIP para esta finalidade:

```
PROCEDURE skip(tosymbol : symbol);
BEGIN
  WHILE sym <> tosymbol do insymbol
END;
```

Este procedimento e' chamado em apenas tres lugares:

1. Chamado pelo programa principal  
Os parametros declarados no programa principal sao reconhecidos mas ignorados. Ao encontrar a declaracao de parametros do programa fonte, o compilador chama SKIP(LPAREN).
2. Chamado pelo procedimento BLOCK  
Na parte de declaracao de um bloco, se o simbolo nao estiver LABEL, CONST, TYPE, VAR, PROCEDURE, FUNCTION e BEGIN, o procedimento BLOCK chama SKIP(SEMICOLON).
3. Chamado pelo procedimento STATELIST.  
Este procedimento analisa a sequencia de comandos. O delimitador da sequencia dos comandos depende do comando que esta' sendo analisado.

REPEAT => UNTIL

LOOP =>	EXIT ou END
BEGIN =>	END

O esquema principal do procedimento é descrito a seguir:

```

PROCEDURE statelist(stopper:symbol);
BEGIN
    statement;
    WHILE (sym<>stopper) AND (sym<>endsy) DO
    IF sym = semicolon
    THEN BEGIN
        insymbol; (*pega o proximo simbolo*)
        statement (*analisa um comando*)
        END
    ELSE BEGIN
        error(14); (*simbolo ilegal*)
        skip(stopper) <==statelist(stopper)
        END
    END;

```

A ideia do algoritmo é bastante simples. Ao detectar um erro na sequencia de comandos, o compilador procura o delimitador da sequencia. Este algoritmo possui duas desvantagens imediatas.

1. O compilador não analisa a parte a partir do primeiro erro detectado até o simbolo delimitador.

Exemplo:

```

REPEAT
    IFF i=0 THEN ... <= erro
    ...
    ... <= Parte não analizada
    ...
UNTIL i < 10;

```

2. O compilador não consegue distinguir o nível de comandos. O seguinte exemplo mostra um caso inconveniente.

Exemplo:

```

REPEAT
    IFF i=0 THEN ...

```

```

    ...
    ...
REPEAT
    ...
    ...
UNTIL i=j;
    ...
    ...
UNTIL i <> j;

```

Note que o segundo UNTIL é reconhecido como o UNTIL do primeiro REPEAT correspondente neste caso.

Algumas pequenas modificações foram feitas para melhorar a recuperação de erros. Uma delas foi feita no procedimento STATELIST. A modificação feita para o procedimento STATELIST é bastante simples. Ao invés de chamar SKIP(STOPPER), o próprio procedimento STATELIST(STOPPER) é chamado recursivamente. Repare que SKIP e STATELIST são iguais no sentido de condição de parada. Sendo a modificação bastante simples, a recuperação de erros ficou substancialmente melhor em relação à original.

A tabela a seguir mostra os números de mensagens de erros dadas pelo Passo 1 original e o Passo 1 modificado sobre um programa simples de 41 linhas.

Passo 1 original

-----

15

Passo 1 modificado

-----

42

#### 4. Debug

A implementação de DEBUG é muito interessante. Como o sistema de desenvolvimento do INTEL 8088 não possui recursos de depuração de erros, isto seria uma ferramenta muito importante. Para implementar o DEBUG, precisaríamos modificar a INTERFACE de execução primeiro. Além de mais, precisamos implementar a checagem dos limites de dados do tipo SCALAR(SCALAR OUT OF RANGE) que está faltando. Se não o DEBUG mesmo não

teria muito sentido. Atualmente o compilador pode verificar opcionalmente indices de ARRAY, overflow, underflow e referencia ilegal pelo apontador. Uma maneira mais facil de implementar o DEBUG seria adaptar o programa de DEBUG feito para compilador de Hamburgo para o compilador NBS como o compilador Sweco fez. O DEBUG requer os seguintes itens:

1. Tabela de LOCATION COUNTER de cada linha do programa fonte.
2. Tabela de todos os identificadores declarados no programa com as informacoes de tipo, atributo, limites, tamanho etc.
3. O apontador de inicio da tabela de simbolos declarados na rotina corrente na pilha.
4. Um pequeno interpretador para comunicar com o usuario durante o DEBUG. O interpretador deve ter uma rotina que calcula o endereco de cada variavel ou subcampo no registro.

[Poul78]

## APENDICE A

### TABELA DE CODIGOS-P DO COMPILADOR NBS

Existem seis Codigos-P do tipo PSEUDO. Estes codigos servem para controlar a montagem de arvore de sintaxe.

0 ... NOP	: Faz nada
1 ... XCH	: Troca os dois elementos que estao no topo da pilha de montagem.
2 ... DEL	: Se a pilha nao estiver vazia, entao abaixa o topo da pilha de um.
5 ... IDENT	: Pega o no' da rotina correntemente montada.
6 ... PROC	: Reconhecimento de nova rotina para montar. O nivel lexico e' somado de um e o tipo da rotina e' verificado.
7 ... ENDP	: Reconhecimento de fim de montagem da rotina correntemente montada. Alem disso, pega as informacoes adicionais: 1. Numeracao da rotina 2. Memoria alocada para parametros 3. Memoria alocada para variaveis 4. Tamanho de valor da funcao

Existem tres tipos de Codigos-P basicamente:

#### 1. Codigos para comandos i

STCL .. STOF : Atribuicao  
MOVEM : Atribuicao  
INVOK : Chamada de Buitin rotina  
DTEMP,KTEMP : Comando WITH  
IFOP : Comando IF  
CASECP,ENTRY : Comando CASE  
LOOPCP,EXITOP: Comandos WHILE,REPEAT,LOOP

FOROP : Comando FOR  
SEQ : Comando composto

2. Códigos para operações :

Existem cinco tipos de operações:

1. Operação ou comparação de um byte.  
UCEQ .. UMIN
2. Operações ou comparação de dois bytes.  
IADD .. IMIN
3. Operação ou comparação sobre tipo booleano.  
EQV .. ANDOP
4. Operação ou comparação sobre tipo conjunto.  
UNION .. SANY
5. Operação ou comparação sobre vetores de caracteres.  
VCEQ .. VCLT

3. Códigos para dados ou endereços :

Existem dois tipos básicos:

1. Código para calcular endereços.  
FIELD .. INDEX
2. Códigos de endereço ou dados básicos.  
VARBL .. VARBL15 , PARAM .. PARAM15 , LITER , RDATA  
(Os números significam níveis léxicos.)

## Tabela de Códigos-P no Compilador NBS

0 NOP	1 XCH	2 DEL
4 NEW	NOTA: Este código não consta no original	
5 IDENT	6 PROC	7 ENDOOP
8 NULL	9 REFER	10 STOL
11 STOR	12 STOF	16 SUCCOP
17 PREDOP	24 UC_EQ	25 UC_NE
26 UC_GT	27 UC_LT	28 UC_GE
29 UC_LT	30 UMAX	31 UMIN
32 IA_ADD	33 ISUB	34 IMUL
35 IDIV	36 IMOD	40 INEG
41 IA_ABS	42 IADD	44 CEIL
45 FLOOR	56 ICEQ	57 IC_NE
53 IC_GT	59 IC_LT	60 IC_GE
61 IC_LT	62 IMAX	63 IMIN
64 FA_ADD	65 FSUB	66 FMUL
67 FDIV	72 FNEG	73 FABS
74 FLCATOP	75 TRUNCOP	76 ROUNDOP
88 FC_EQ	89 FC_NE	90 FC_GT
91 FC_LT	92 FC_GE	93 FC_LT
94 FM_MAX	95 FMIN	96 NOTOP
104 EQV	105 XOR	106 NIMP
107 RIMP	108 IMP	109 NRIMP
110 DROP	111 ANDOP	112 COMPL
113 UNION	114 INTER	115 SDIFF
117 SGENS	118 SADEL	119 EMPTY
120 SC_EQ	121 SC_NE	122 SC_GT
123 SC_LT	124 SC_GE	125 SC_LT
126 SIN	127 SANY	131 FIELD
132 OFSET	133 INDIR	134 INDEX
135 MOVEM	138 INVOK	140 RTEMP
141 DTEMP	144 IFOP	145 CASEOP
146 ENTRY	147 LOOPOP	148 EXITOP
149 FOROP	152 SEQ	162 LITER
163 RDATA	164 LITD	168 VCEQ
169 VC_NE	170 VCGT	171 VC_LT
172 VC_GE	173 VC_LT	176 VARBL
176 VARBL0	177 VARBL1	178 VARBL2
179 VARBL3	180 VARBL4	181 VARBL5
182 VARBL6	183 VARBL7	184 VARBL8
185 VARBL9	186 VARBL10	187 VARBL11
188 VARBL12	189 VARBL13	190 VARBL14
191 VARBL15	192 PARAM	192 PARAMO
193 PARAM1	194 PARAM2	195 PARAM3
196 PARAM4	197 PARAM5	198 PARAM6
199 PARAM7	200 PARAM8	201 PARAM9
202 PARAM10	203 PARAM11	204 PARAM12
205 PARAM13	205 PARAM14	207 PARAM15
208 CALL	208 CALLO	209 CALL1
210 CALL2	211 CALL3	212 CALL4
213 CALL5	214 CALL6	215 CALL7
216 CALL8	217 CALL9	218 CALL10
219 CALL11	220 CALL12	221 CALL13
222 CALL14	223 CALL15	

## APENDICE 3

### Lista de rotinas de suporte durante execucao

#### **1. CHKMEM :**

Compara o nivel da pilha no SP e proximo endereço disponivel para area de HEAP que esta' armazenado no endereço HEAPPTR. Se o valor no SP estiver maior do que o valor que esta' no HEAPPTR entao dar a mensagem "NO MORE MEMORY TO ALLOCATE" e volta o controle ao monitor. Esta rotina e' chamada na entrada de rotina e chamada do comando NEW incondicionalmente.

#### **2. NILREF :**

Ao referir um endereço através de um apontador, esta rotina verifica se o valor do pontador e' NIL. Se o valor estiver NIL dar a mensagem "REFERENCE TO NIL" e' volta o controle ao monitor. Esta rotina e' chamada opcionalmente. Ao executar o Passo 2, o programador pode indicar a option RUNCHK. O valor NIL e' representado como 0 no caso do compilador NBS.

#### **3. ILLREF :**

Ao referir um endereço que esta' indicado através de um apontador, esta rotina verifica se o endereço indicado esta' na area HEAP ou nao. Esta rotina tambem e' chamada opcionalmente.

#### **4. IDXCHK :**

Ao referir um campo do tipo ARRAY, esta rotina verifica se o valor de indice calculado durante execucao esta' entre nos limites inferior e superior. Se nao da' a mensagem "ARRAY INDEX OUT OF RANGE AT ..." e devolve o controle ao monitor. A diferenca entre o Compilador de Hamburgo do DEC-10 e o nosso compilador neste caso e' que o nosso informa o numero de linha do programa fonte onde este tipo de erro ocorreu durante execucao. Esta rotina e' chamada opcionalmente tambem.

5. **CSCMK :**  
Ao calcular o valor da expressao do comando CASE, esta rotina verifica se o valor calculado e' menor do que de 1 byte. (O valor da expressao do comando CASE no caso do Compilador NsS e' representado por um byte apenas). Esta rotina e' chamada opcionalmente.
6. **WRINTI :**  
Rotina que imprime o valor que esta' no registrador AX para TTY.
7. **RDINI :**  
Rotina que le um numero inteiro de TTY e devolve o valor lido no registrador AX. Se haver um error na leitura, a rotina da' a mensagem "ILLEGAL INPUT DATA" e devolve o controle para o monitor.
8. **WRISBL :**  
Rotina que imprime o valor booleana que esta' no registrador AX.
9. **RDEGLN :**  
Rotina que le ate a fim da linha no TTY.
10. **WRISIR :**  
Rotina que imprime uma cadeia de caracteres no TTY. O endereco inicial da cadeia esta' no registrador SI e o numero de caracteres para imprimir esta' no registrador AX. Estes valores sao inicializados antes da chamada da rotina pelo Passo 2.
11. **RDCCHAR :**  
Rotina que le um caracter do TTY e armazenar o codigo do caracter lido no registrador AL.
12. **WICHAR :**  
Rotina que imprime o caracter correspondente do valor que esta' no registrador AL para o TTY.
13. **WIREAL :**  
Rotina que imprime o valor do tipo real que esta' no registrador AX no format FOCUS para TTY.
14. **EMUL :**  
Rotina que multiplica os valores do tipo real que estao no AX e CX e armazena o resultado no AX.
15. **EDIV :**  
Rotina que multiplica os valores do tipo real que estao no AX e CX e armazenar o resultado no AX.
16. **ESQR :**  
Rotina que calcula o quadrado que esta' no AX e devolve o resultado no AX.

**17. FMAX :**

Rotina que calcula o valor maximo dos numeros reais que estao no AX e CX e devolve o resultado no AX.

**18. FMIN :**

Rotina que calcula o valor minimo dos numeros reais que estao no AX e CX e devolve o resultado no AX.

**19. VCEQ VCNE VCGL VCLE VCSE VCLI :**

Rotina que compara duas cadeias de caracteres e devolve o resultado booleano no registrador AL. Os enderecos iniciais de cadeias estao nos registradores SI e DI e o comprimento de cadeias esta' no registrador CX.

## APENDICE C

### **Lista de opções de compilação do compilador**

#### **1. SELECT :**

O Passo 2 pergunta se cada rotina do programa fonte deve ser compilado interativamente pelo terminal.

#### **2. CHECK :**

Verifica se a árvore de sintaxe montada no Passo 2 está correta ou não.

#### **3. KEEP :**

Normalmente o Passo 2 apaga o arquivo que contém código intermediário gerado pelo Passo 1 ao terminar a execução. Com esta opção, o Passo 2 deixa o arquivo. Existem dois programas de suporte; TREE.PAS e PCCODE.PAS que analisa o código intermediário.

#### **4. IRACE :**

O Passo 2 marca o inicio e o fim de cada comando compilado para o código gerado em linguagem de montagem.

#### **5. BUNCHK :**

O Passo 2 gera código para verificação em tempo de execução do tipo:

1. ARRAY INDEX OUT OF BOUND

2. REFERENCE TO NIL

3. ILLEGAL REFERENCE OF MEMORY

4. CASE SELECTER BIGGER THAN ONE BYTE

5. OVERFLOW E UNDERFLOW

6. **DUMPI :**  
O Passo 2 mostra todos os passos de modificacao de arvore de expressao feita para a otimizacao de codigo. Desta maneira podemos verificar se a modificacao de arvore de expressao e' feita corretamente.
7. **NCLST :**  
O Passo 1 nao gera o arquivo de listagem de compilacao.
8. **NOIAS :**  
O Passo 1 nao mostra a tabela de simbolos e seu enderecos na listagem.
9. **NOIMAC :**  
O Passo 2 nao copia as rotinas intrinsecas no inicio do codigo gerado.
10. **PRINI :**  
O Passo 2 imprime a arvore de sintaxe de cada rotina do programa fonte antes de gerar codigo em linguagem de montagem do INTEL 8088.
11. **SIA :**  
O Passo 2 mostra a estatisticas de tipos de atribuicoes e a otimizacao PEEPHOLE feita no registrador AX e BX sobre o programa fonte.

APENDICE D  
BIBLIOGRAFIA

1. Aho, Alfred  
Principles of Compiler Design  
Addison-Wiley 1977
2. Amman, W. Nori. U  
The Pascal <P> Compiler: Implementation Notes:  
Berichte des Instituts fur Informatik
3. Amman, U.R.S  
On Code Generation in a Pascal Compiler  
Sowftware-Practice and experiences, vol. 7, 1977
4. Atkinson, L.V.  
Optimizing Two-state Case Statements in Pascal  
Sowftware-Practice and experiences, vol. 12, 1982
5. Barr, John R.  
Pascal for RSX-11D and RSX-11M  
Proceddings od Digital Equipment Computer Users Society  
1977
6. Barron, David William  
Pascal: The language and its implementation  
Wiley, 1981
7. Bell, James R.  
Threaded Code  
Comm. ACM jun 1973, vol 16
8. Berry, R.E.  
Experiences with the Pascal P-Compiler  
Sowftware-Practice and experiences, vol. 8, 1978
9. Bron, C.  
A Pascal Compiler for PDP 11 Minicomputers  
Sowftware-Practice and experiences, vol. 6, 1976

10. Cael, William  
RT/RSX : RT - 11 as a SRX-11/M TASK  
Jorn. Proceedings of Digital Equipment Computer Users Society  
1977
11. Colin, A.J.T.  
Note on coding Reverse Polish expression for Single-address computers with one accumulator  
Computer Journal, vol 6, 1963
12. Cornelius, S.J.  
Modification of the Pascal-P compiler for a Single-accumulator One-address Minicomputer  
Software-Practice and experience, vol 10, 1980
13. Floyed, Robert W.  
An Algorithm for Coding Efficient Arithmetic Operations  
Comm. ACM
14. Forsyth, Charles  
Compiler and Pascal in the new Microprocessors  
BYTc august 1979
15. Gries, David  
Compiler Construction for Digital Computers  
Wiley, 1971
16. Hartman, A.C.  
Architectural issues in the design of the INTEL 8086  
Electronic engineering, December 1980
17. Hopgood, F.R.A.  
Compiler Techniques  
Mac Donald, 1969
18. Kowaltowski, Tomasz,  
Runtime systems for programing language
19. Kowaltowski, Tomasz  
Implementacao de linguagem de programacao  
Escola de Computacao, 1979
20. Lecarme, oliver  
Self-compiling Compilers: An Appraisal of their Implementation and Portability  
Software-Practice and Experiences, vol 8, 1978
21. McKeeman, W.M.  
Peephole Optimization  
Comm. ACM. vol 8. November 1965
22. Poulsen, C. Steven  
A high level symbolic DEBUGGER for Pascal  
Proceedings of Digital Equipment Computer Users Society

1978

23. Ravenel  
Toward a Pascal Standard  
Computer, april 1979
24. Richmond  
Proposals for Pascal  
Pascal Newsletter, No.3 May 1977
25. Sale, Arthur  
The Implementation of CASE Statements in Pascal  
Software-Practice and experiences, vol. 11, 1981
26. Schneider, G. Michael  
Pascal: An overview  
Computer, April 1979
27. Stevenson, Gordon  
Code Generation with a Recursive Optimizer  
Software-Practice and experiences, vol. 10, 1980
28. Ullman,  
The generation of optimal code for arithmetic  
expressions  
J. ACM . vol 17, 1970
29. Wilson, I.R.  
Pascal for School and Hobby Use  
Software-Practice and Experiences, vol 10 1980
30. Wirth, Niklaus  
Pascal: User a Manual and Report  
Springer, 1976
31. Wirth  
Algorithms + Data structures = Programs  
Printice-Hall, 1976
32. Wirth  
Systematic Programming  
Printice-Hall, 1973