Departamento de Ciência da Computação – IME-USP

MAC 110 — Introdução à Computação

BCC — PRIMEIRO SEMESTRE DE 2007

Terceiro Exercício-Programa | Prazo de entrega: até **12 de junho de 2007.**

Compressão de Arquivos

O objetivo deste exercício-programa é implementar um compressor de arquivos utilizando um algoritmo que foi proposto por J. Ziv e A. Lempel, em 1977, e que ficou conhecido como LZ77. Uma variante refinada desse algoritmo, conhecida como DEFLATE, é a base para dois formatos populares de arquivos comprimidos (ZIP e gzip), para a biblioteca de compressão de arquivos zlib e para inúmeros programas, incluindo PKZIP, WinZip, WinRAR e gzip.

Quem estiver curioso para saber mais sobre o LZ77 e sobre a utilização de sua variante DEFLATE em programas de compressão de arquivos, visite as seguintes páginas:

- `http://en.wikipedia.org/wiki/LZ77_and_LZ78`
- `http://en.wikipedia.org/wiki/DEFLATE`
- `http://en.wikipedia.org/wiki/Gzip`
- `http://en.wikipedia.org/wiki/Zlib`
- `http://en.wikipedia.org/wiki/ZIP_file_format`

Descrição do Algoritmo LZ77

A idéia fundamental é muito simples: à medida que um arquivo é lido, seqüências repetidas de caracteres são substituídas por *referências* para ocorrências prévias dessas seqüências. Essas referências são pares ($dist, compr$), onde $dist$ é a distância (número de caracteres) entre uma ocorrência da seqüência e a sua ocorrência prévia, e $compr$ é o comprimento dessa seqüência. Quando um caractere c ocorrer pela primeira vez no texto, a "referência" será o par $(0, c)$.

Exemplo

Arquivo original: `le=0;while(le==0){hi=0;while(hi==0){hi=`

Arquivo comprimido: `0l 0e 0= 00 0; 0w 0h 0i 8 2 0( 11 3 12 2 0) 0{ 12 2 18 9 11 3 18 7`

Repare que o arquivo original possui 39 caracteres (39 bytes), mas o arquivo comprimido possui 18 pares (36 bytes). A 9ª referência, ou seja, o par 8 2, está indicando que os caracteres `le` da primeira ocorrência da palavra `while` já ocorreram no texto a uma distância de 8 caracteres. Note agora a 11ª referência, ou seja, o par 11 3. Apesar da seqüência `le` já ter ocorrido no final da palavra `while`, é mais vantajoso registrar a repetição da seqüência `le=`, que possui 3 caracteres e ocorre a uma distância de 11 caracteres. Repare também na economia de caracteres causada pela antipenúltima referência: a seqüência `=0;while(` foi substituída pelo par 18 9.

O algoritmo de expansão (ou descompressão) é ainda mais simples: basta trocar cada referência por uma cópia do trecho referenciado por ela. No exemplo anterior, após a descompressão dos 8 primeiros pares, todos começando com 0, teremos o texto `le=0;whi`. A descompressão do 9º par, ou seja, do par 8 2, pode ser interpretada como: "olhe oito caracteres para trás e copie dois caracteres a partir daí". Obtém-se, então, o texto `le=0;while`.

Implementação do Algoritmo

Na prática, os comprimentos das repetições procuradas têm um limite máximo e as buscas não são feitas em toda a parte já vista do arquivo original, mas apenas numa 'janela' contendo o trecho mais recentemente examinado desse arquivo. Como essa 'janela' parece deslizar sobre o arquivo original, o algoritmo LZ77 é também conhecido como "compressão com janela deslizante".

Declare um vetor de caracteres *janela*, com 510 posições, indexadas de 0 a 509. A primeira metade desse vetor (posições de 0 a 254), denominada *dicionário*, armazena o trecho mais recentemente examinado do arquivo original; a segunda metade (posições de 255 a 509), denominada '*look-ahead*', armazena o próximo trecho do arquivo original a ser comprimido.

Compressão

Cada passo do processo de compressão consiste das seguintes ações:

a) procure nos caracteres do '*look-ahead*' (começando da posição 255) o segmento de maior comprimento que seja uma repetição de algum segmento de caracteres do *dicionário* (posições 0 a 254) e escreva no arquivo comprimido o par $(dist, compr)$ correspondente;

b) desloque todos os caracteres do vetor *janela* de *compr* posições para a esquerda (ou uma posição, no caso de $dist = 0$;

c) leia do arquivo original os próximos *compr* caracteres necessários para preencher o '*look-ahead*' (ou apenas um caractere, no caso de $dist = 0$.

Apenas para facilitar a explicação, vamos supor que o vetor *janela* tem apenas 22 posições. No exemplo visto anteriormente, teremos:

- Situação após o 1º passo (quando foi gerado o par `01`):

dicionario	'look-ahead'
l	e = 0 ; w h i l e (l
0 … 10	11 … 21

- Situação após o 10º passo (já foram gerados os 10 primeiros pares, de `01` a `0(`):

dicionario	'look-ahead'
l e = 0 ; w h i l e (	l e = = 0) { h i = 0
0 … 10	11 … 21

- No 11º passo ocorrerá o seguinte:
  - será descoberto que o segmento de maior comprimento do '*look-ahead*' que seja uma repetição de algum segmento do *dicionário* é `le=`, o que gera o par $(dist, compr) = (11, 3)$;
  - todos os caracteres de *janela* serão deslocados de 3 posições para a esquerda;
  - serão lidos mais 3 caracteres do arquivo original:

dicionario	'look-ahead'
`0 ; w h i l e ( l e =`	`= 0 ) { h i = 0 ; w h`
0 ... 10	11 ... 21

Note que tanto a distância *dist* quanto o comprimento *compr* podem variar apenas de 0 a 255, ou seja, cabem em um byte.

Descompressão

Para a descomprimir um arquivo que foi comprimido pelo método acima, também é preciso utilizar uma *janela* com um *dicionário* (contendo os últimos 255 caracteres já descomprimidos) e um '*look-ahead*' (onde são armazenados os caracteres que estão sendo gerados pela descompressão do par $(dist, compr)$ que acabou de ser lido).

Operação do programa

Inicialmente, seu programa deve perguntar ao usuário se deseja comprimir ou descomprimir um arquivo. Em seguida, o programa deve pedir os nomes dos arquivos de entrada e de saída. Finalmente, o programa deve realizar a tarefa desejada.

Note que o arquivo resultante de uma compressão pode ter mais bytes do que o arquivo original. (Quando ocorre esta situação?) Seu programa deve avisar caso isto ocorra. Em caso contrário, o programa deve determinar também o fator de compressão *fc*, definido como

$$fc = ((nbao - nbac)/nbao) * 100$$

onde

$nbac$ = número de bytes do arquivo comprimido e
$nbao$ = número de bytes do arquivo original.

Requisitos

(1) O seu programa deve conter pelo menos as seguintes funções:

  - comprimir um arquivo;
  - descomprimir um arquivo;
  - deslocar todos os caracteres no vetor *janela* de n posições para a esquerda;
  - determinar o par $(dist, compr)$ para o próximo trecho a ser comprimido.

Para esta última funcão, considere como parâmetros o vetor *janela*, a *posição inicial* do texto que já passou para a parte do dicionário (repare que no início o dicionário está vazio e, portanto, esta posição é 255), a *posição do último caractere* do 'look-ahead' (repare que no final da compressão o 'look-ahead' vai esvaziando), e o par ($dist$, $compr$) a ser determinado. Exemplo:

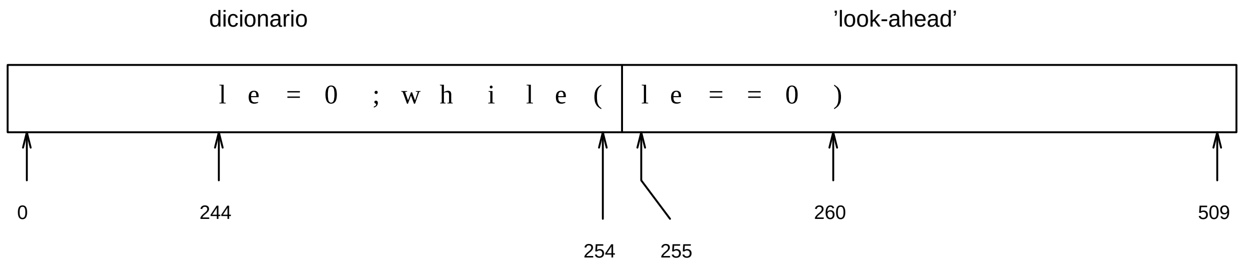

Nesse exemplo, a posição inicial é 244, a posição do último caractere é 260, e o par ($dist$, $compr$) devolvido é (11, 3).

(2) Teste seu programa com os seguintes arquivos:

- um arquivo contendo um texto literário;
- o arquivo-fonte deste exercício-programa;
- um arquivo cujo arquivo comprimido correspondente tenha muito mais bytes do que o original;
- um arquivo cujo arquivo comprimido correspondente tenha muito menos bytes do que o original.

(3) Não é possível examinar o conteúdo de um arquivo binário diretamente num editor de textos. Então, para que você possa conferir os pares ($dist$, $compr$) gerados durante a fase de compressão, seu programa deverá criar ao mesmo tempo um arquivo texto contendo esses pares.

(5) Não devem ser usadas variáveis globais em nenhuma das funções do seu programa.

Observações Importantes

1) Todos os exercícios-programa devem ter um cabeçalho como o seguinte:

```
/*******************************************************/
/* Aluno: Fulano de Tal                                */
/* Número USP: 12345678                                */
/* Exercicio-Programa 3 -- Compressão de Arquivos      */
/* MAC110 (BCC) -- 2007 -- Professor: Reverbel         */
/* Compilador: ... (DevC++ ou gcc) versão ...          */
/*******************************************************/
```

2) O exercício-programa é <u>estritamente individual</u>. Exercícios copiados (com ou sem eventuais disfarces) receberão nota ZERO.
3) <u>Exercícios atrasados não serão aceitos</u>.
4) Exercícios com erros de sintaxe (ou seja, erros de compilação) receberão nota ZERO.
5) É <u>muito importante</u> que seu programa tenha comentários e esteja bem indentado, ou seja, digitado de maneira a ressaltar a estrutura de subordinação dos comandos do programa (conforme visto em aula). A avaliação dos exercícios-programa levará isto em conta.
6) Cada programa deve ter sido executado tantas vezes quantas forem necessárias para testar os vários casos possíveis para as entradas.
7) Você entregará seu exercício-programa através do sistema Paca/Moodle (`http://paca.ime.usp.br`). Para isto você precisa estar cadastrado nesse sistema (use o seu número USP para se cadastrar) e registrado no Paca como aluno da disciplina `MAC110-BCC` (uma vez cadastrado no Paca, basta entrar na área da disciplina `MAC110-BCC` que o sistema perguntará a você se deseja se registrar como aluno da disciplina).
8) Entregue apenas o programa fonte em C, num arquivo com nome `ep3-`<*seu-número-USP*>`.c`. (Exemplo: se seu número USP for 12345678, você deverá entregar um arquivo `ep3-12345678.c`.)
9) Enquanto o prazo de entrega não expirar, você poderá entregar várias versões do mesmo exercício-programa. Apenas a última versão entregue será guardada pelo sistema. Encerrado o prazo, o sistema não aceitará mais a entrega de exercícios-programa. Não deixe para entregar seu exercício na última hora!
10) Guarde uma cópia do seu exercício-programa pelo menos até o final do semestre.

Bom trabalho!