MAC–IME–USP

Carlos Eduardo Ferreira
Sala 297A Tel.: 818 6140
e-mail cef@ime.usp.br

MAC 5710 – Estruturas de Dados

Primeiro semestre de 1999

Exercício-Programa 4 – Entrega: **24 de junho de 1999**

Códigos de Huffman

Uma aplicação interessante de árvores binárias em codificação de dados a serem transmitidos e compactação de arquivos são os códigos de Huffman. Para enviar uma mensagem através de um cabo de transmissão os caracteres da mensagem são enviados um a um modificados através de alguma tabela de codificação. Em geral, esse código é um número binário. Como a velocidade de transmissão depende do comprimento deste código, é interessante tornar a mensagem o mais curta possível. Um algoritmo de determinação de códigos binários para caracteres baseado na freqüência de uso destes caracteres foi sugerida por Huffman. A idéia é associar números binários com menos bits aos caracteres mais usados nos textos. Se você quiser saber mais sobre códigos de Huffman, consulte o ótimo livro [1].

Por exemplo, suponha que a mensagem seja composta pelos caracteres A, B, C, D, E e R e que o número de vezes que estas letras são usadas na mensagem seja resp. 22, 8, 10, 12, 18 e 7. A idéia é construir uma árvore binária baseada na freqüência de uso destas letras de tal forma que as folhas correspondam às letras; e as letras mais freqüentemente usadas (como A e E) estão mais próximas da raiz que as menos usadas (como B e R). Para isso, construiremos a árvore binária a partir das folhas, colocando nos nós internos um número correspondente à soma da freqüência dos seus descendentes.

A seguir, mostramos a construção da árvore binária para o exemplo mostrado acima. Em cada passo do algoritmo teremos uma coleção de árvores binárias. À raiz de cada uma dessas árvores está associado um número (freqüência de seus descendentes). Escolhemos então, as duas árvores dessa coleção com menor freqüência e as transformamos numa só, ligando-as a uma nova raiz cujo valor será dado pela soma dos valores das duas subárvores. Observe o exemplo abaixo:

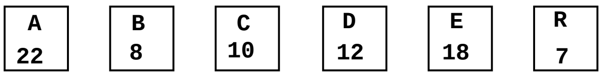

Selecionamos as duas árvores de menor valor (8 e 7) e as juntamos em uma árvore só.

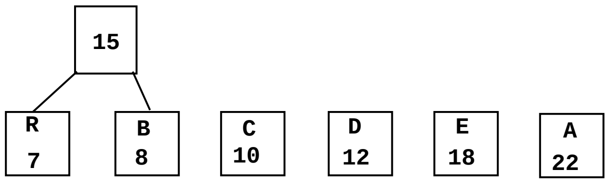

Repetindo o processo, escolhemos as árvores com raiz (10 e 12).

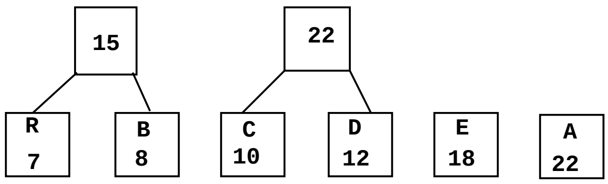

Agora escolhemos (18 e 15),

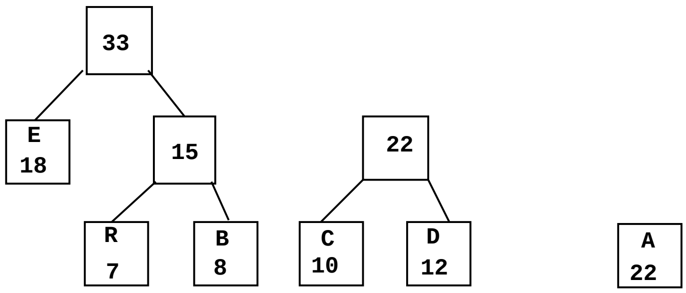

Depois (22 e 22),

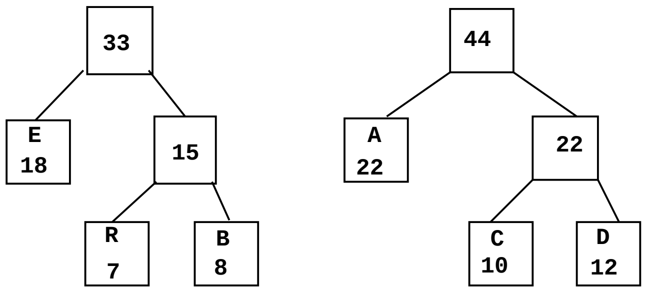

E finalmente (33 e 44).

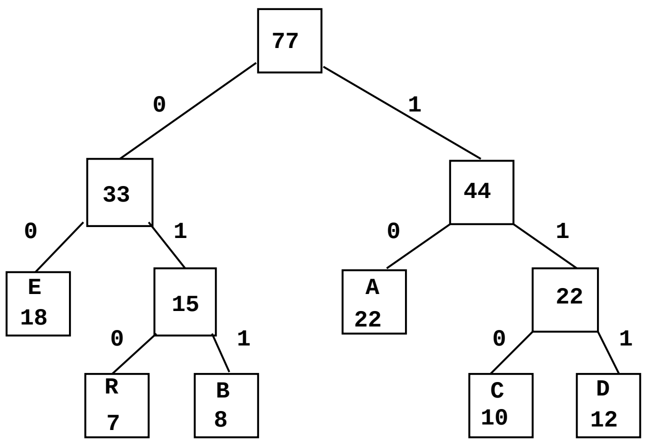

Associamos, então, à árvore final assim construída 0 às arestas que ligam o vértice com seu filho esquerdo e 1 às arestas que ligam o vértice com seu filho direito. O código correspondente a cada letra será então formado pelo número binário associado ao caminho da raiz até a folha correspondente. No caso acima, temos a seguinte tabela:

A	10
B	011
C	110
D	111
E	00
R	010

No exemplo acima pudemos diminuir o tamanho da codificação de todos os caracteres, mas dependendo da árvore isso nem sempre acontece.

Utilizando a tabela acima, a mensagem ABRACADABRA será codificada pela seqüência de bits 1001101010110101111001101010. Assim, pudemos compactar a mensagem original de 88 bits para 28 bits.

O objetivo deste exercício–programa é construir um compactador de arquivos baseado na estratégia mostrada acima. Duas estratégias possíveis de compactação são as seguintes:

- árvore fixa.
  A idéia é inicialmente ler diversos tipos de textos (programas, arquivos de dados, textos escritos), contando o número de ocorrências de cada caractere. A partir de então seu programa montará a árvore como descrito neste enunciado, e usará a mesma árvore para compactar e descompactar os textos.

- árvore variável.
  Para cada texto lido constrói-se a "árvore ótima" para aquele texto e compacta o texto usando essa árvore. A desvantagem nesse caso é que devemos guardar essa árvore junto com o arquivo compactado para descompactar futuramente.

Compare essas duas estratégias (em porcentagem de compactação, tempo de processamento, etc.) e compare também seu programa com pacotes comerciais de compactação de textos.

Nesse exercício–programa, além da listagem e do disquete, você deve entregar um pequeno relatório com seus testes comparando as diversas estratégias (pode implementar outras!) e os pacotes comerciais.

Referências

[1] T. H. Cormen, C. E. Leiserson, R. L. Rivest, *Introduction to Algorithms* (1990), McGraw Hill.

[2] D. A. Huffman, "A Method for the Construction of Minimum Redundancy Codes", *Proceedings IRE* 10, 40, 1098 – 1101 (1952).

[3] D. A. Lelewer, D. S. Hirschberg, "Data Compression", *ACM* 19, 3, 261–296 (1987).