

Exame de Compressão e Codificação de Dados

Mário Figueiredo

Secção de Telecomunicações - DEEC
Instituto Superior Técnico

24 de Fevereiro de 1999

1. Considere uma fonte que emite símbolos de um alfabeto $\mathcal{X} = \{1, 2, 3, 4\}$ com probabilidades $p(1) = 0.3$, $p(2) = 0.4$, $p(3) = 0.3$, $p(4) = 0$. A entropia desta fonte é aproximadamente igual a 1.571 bits/símbolo.
 - a) Desenhe um código de Huffman binário para esta fonte e calcule o seu comprimento médio. Compare com a entropia e comente.
 - b) Considere a extensão de segunda ordem da fonte. Desenhe um código de Huffman binário para esta extensão da fonte, calcule o seu comprimento médio, compare com a entropia e comente.
 - c) Qual a ordem de extensão necessária para garantir que o comprimento médio obtido não se afasta mais do que 0.01 bits/símbolo da entropia da fonte. Justifique.
2. Uma fonte de Markov é caracterizada pela distribuição de probabilidade do símbolo X_n , condicionada ao símbolo X_{n-1} , designada por $p(X_n|X_{n-1})$. Quando a fonte é estacionária, esta distribuição não depende de n , pelo que temos $p(X_n|X_{n-1}) = p(X_m|X_{m-1})$, para quaisquer dois instantes n e m . Considere então uma fonte de Markov, gerando símbolos do alfabeto $\{A, B, C, D\}$, cuja distribuição de probabilidade condicionada é dada pela tabela seguinte:

$p(X_n X_{n-1})$	$X_n = A$	$X_n = B$	$X_n = C$	$X_n = D$
$X_{n-1} = A$	1/2	1/4	1/4	0
$X_{n-1} = B$	1/4	1/4	1/4	1/4
$X_{n-1} = C$	1/2	1/4	1/8	1/8
$X_{n-1} = D$	1/8	1/8	1/4	1/2

Sabe-se que $[0.3791, 0.2288, 0.2222, 0.1699]$ é a distribuição estacionária desta fonte de Markov.

- a) Calcule a taxa de entropia condicional deste processo. Compare com a entropia da distribuição estacionária e comente.
- b) Suponha agora que se pretende desenhar um sistema de codificação para esta fonte e que se opta por desenhar 4 códigos diferentes, um para cada possível símbolo anterior. Desenhe estes códigos por simples inspeção da tabela (isto é, não é necessário recorrer à técnica de Huffman) e calcule o comprimento médio de cada um deles, condicionado ao respectivo símbolo anterior. Com base no vector de distribuição estacionário acima indicado, calcule o comprimento médio geral deste procedimento de codificação; compare com a taxa de entropia e com a entropia da distribuição estacionária e comente.
- c) Considerando agora uma fonte cuja matriz de transição é que se apresenta de seguida, repita a alínea anterior após determinar a sua distribuição estacionária.

$p(X_n X_{n-1})$	$X_n = A$	$X_n = B$	$X_n = C$	$X_n = D$
$X_{n-1} = A$	0	1	0	0
$X_{n-1} = B$	0	0	1	0
$X_{n-1} = C$	0	0	0	1
$X_{n-1} = D$	1	0	0	0

3. Considere o canal de apagamento simétrico (CAS) com erros, ilustrado abaixo, cujo alfabeto de entrada é $\mathcal{X} = \{0, 1\}$ e o de saída é $\mathcal{Y} = \{0, 1, \star\}$. As probabilidades de transição são $p(Y = \star|X = 0) = \varepsilon$, $p(Y = \star|X = 1) = \varepsilon$, $p(Y = 1|X = 0) = p$, $p(Y = 0|X = 0) = p$.

- a) Determine a matriz deste canal.
 b) Considere que na saída do canal acima descrito se liga um outro canal, cujo alfabeto de entrada é $\{0, 1, \star\}$ e o de saída é $\{0, 1\}$, tal como indicado na figura. Este segundo canal, quando recebe na sua entrada o símbolo \star , coloca na saída um 0 ou um 1, aleatoriamente com equiprobabilidade.

Determine a matriz do canal resultante e calcule a sua capacidade.

- c) Determine a matriz e calcule a capacidade do chamado canal “Z”, cujo diagrama é:

4. Considere o seguinte procedimento de codificação do tipo Lempel-Ziv: cada subsequência de símbolos de comprimento superior ou igual a L que já tenha ocorrido anteriormente é substituída por um par de “ponteiros” com o formato (p_1, p_2) , indicando que a ocorrência anterior se verificou na posição p_1 , a contar do início, e que o comprimento da subsequência é p_2 .

- a) Com $L = 3$, ilustre detalhadamente o funcionamento desta técnica ao codificar e, em seguida, decodificar a sequência “*abccbabccbabca*”.
 b) Suponha que se utilizam 4 *bytes* para escrever o ponteiro p_1 . Quanto a p_2 , utiliza-se o seguinte esquema de codificação:

$$\underbrace{00\dots0}_{p_2+1 \text{ 0's}} 1001$$

Sabendo que os símbolos das sequências a codificar correspondem a um *byte*, qual o valor mínimo de L para que este procedimento resulte sempre em compressão da sequência original.

5. Considere um quantizador escalar $\mathcal{Q}(\cdot)$ cuja gama de valores de entrada é $[0, 10[$ e cujas células são os intervalos da forma $R_k = [k/2, (k+1)/2[$, para $k = 0, 1, \dots, 19$. Assuma que a entrada é uma variável aleatória X cuja função densidade de probabilidade $f_X(x)$ é uniforme em $[0, 10[$.

- a) Determine, justificando, o *code book* óptimo $\{y_0, y_1, \dots, y_{19}\}$, isto é, aquele que minimiza o erro quadrático médio

$$E \left[(X - \mathcal{Q}(X))^2 \right] = \int_{-10}^{10} f_X(x) (x - \mathcal{Q}(x))^2 dx.$$

Qual a distorção quadrática média resultante?

- b) Considerando agora que a função densidade de probabilidade $f_X(x)$ é dada por $f_X(x) = x/50$, para $x \in [0, 10[$. O quantizador obtido na alínea a) é ainda óptimo? Se não for, calcule a expressão geral dos elementos do codebook óptimo $\{y_i, i = 0, \dots, 19\}$ para as mesmas células. Calcule o valor de y_0 e interprete o resultado.