

Parte I

Compressão de Fontes com Perdas

2

Fundamentos da Compressão de Fontes

Neste capítulo, são apresentados os conceitos fundamentais da teoria da compressão de fontes com perdas. Esta teoria pode ser dividida em duas partes: a *teoria taxa-distorção* [11], que busca estabelecer os limites teóricos da compressão de fontes, e a *teoria de quantizadores* [18], que tem como objetivo encontrar esquemas práticos de compressão que atinjam estes limites.

Este capítulo está organizado da seguinte forma. A Seção 2.1 apresenta a teoria taxa-distorção; nesta seção, alguns conceitos importantes são definidos e o teorema da compressão de fontes é apresentado. Na Seção 2.2, são apresentados os limites teóricos de compressão para algumas fontes de interesse nesse trabalho. A teoria de quantização é desenvolvida na Seção 2.3, e posteriormente particularizada para quantizadores de taxa fixa e de taxa variável, respectivamente, nas seções 2.4 e 2.5.

2.1

Teoria Taxa-Distorção

Um problema qualquer da teoria taxa-distorção é descrito especificando-se a fonte de informação e a medida de distorção consideradas, dois conceitos que são definidos a seguir.

Definição 2.1 (Fonte sem Memória) Uma *fonte de informação sem memória* é uma seqüência semi-infinita de variáveis aleatórias X_1, X_2, \dots independentes e identicamente distribuídas (i.i.d.) sobre o mesmo conjunto \mathcal{X} , o qual é chamado de *alfabeto da fonte*. A fonte é dita *discreta* quando o alfabeto \mathcal{X} é discreto, e *contínua* quando \mathcal{X} é contínuo. Uma vez que X_1, X_2, \dots são variáveis aleatórias i.i.d., uma fonte sem memória também pode ser denotada por uma variável aleatória genérica X .

Definição 2.2 (Medida de Distorção) Uma *medida de distorção* é um mapeamento

$$d : \mathcal{X} \times \hat{\mathcal{X}} \rightarrow \mathbb{R}^+ \quad (2-1)$$

dos pares (x, \hat{x}) , $x \in \mathcal{X}$, $\hat{x} \in \hat{\mathcal{X}}$ para o conjunto dos números reais não-negativos \mathbb{R}^+ . A distorção $d(x, \hat{x})$ é uma medida do custo de se representar o símbolo x pelo símbolo \hat{x} .

Uma medida de distorção de grande interesse nesse trabalho é a *distorção de erro quadrático*, a qual é dada pela seguinte expressão:

$$d(x, \hat{x}) = (x - \hat{x})^2. \quad (2-2)$$

Estendemos o conceito de distorção para seqüências de n símbolos $x^n = (x_1, \dots, x_n)$ e $\hat{x}^n = (\hat{x}_1, \dots, \hat{x}_n)$ através da seguinte definição:

Definição 2.3 (Distorção entre Seqüências) A *distorção entre as seqüências* x^n e \hat{x}^n é definida como

$$d(x^n, \hat{x}^n) = \frac{1}{n} \sum_{j=1}^n d(x_j, \hat{x}_j). \quad (2-3)$$

Considere agora o problema de representar as n saídas de uma fonte através de um número finito de bits. A seqüência X^n produzida pela fonte é representada através de um índice inteiro $i = \alpha(X^n)$, como mostrado na Fig. 2.1. A partir deste índice, é gerada uma seqüência de reprodução $\hat{X}^n = \beta(i)$, a qual é entregue ao usuário como estimativa de X^n .

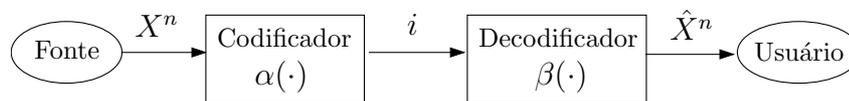


Figura 2.1: Código de bloco para compressão.

Como a função α é em geral não-injetora, a seqüência reconstruída pode ser diferente da original, o que significa que o esquema introduz distorção. Deseja-se representar a seqüência X^n através de \hat{X}^n utilizando nR bits e com a menor distorção esperada possível.

Definição 2.4 (Código de Bloco para Compressão) Seja o conjunto $\mathcal{I} = \{1, 2, \dots, M\}$, onde $M = 2^{nR}$. Um *código de bloco para compressão*, de dimensão n e cardinalidade M , consiste de uma *função de codificação*

$$\alpha : \mathcal{X}^n \rightarrow \mathcal{I} \quad (2-4)$$

que mapeia uma seqüência $x^n \in \mathcal{X}^n$ em um índice $i \in \mathcal{I}$, e uma *função de decodificação (ou reprodução)*

$$\beta : \mathcal{I} \rightarrow \hat{\mathcal{X}}^n \quad (2-5)$$

que mapeia um índice $i \in \mathcal{I}$ em uma seqüência $\hat{x}^n \in \hat{\mathcal{X}}^n$.

O código é aplicado a n saídas de uma fonte sem memória de alfabeto \mathcal{X} , agrupadas em uma seqüência $X^n \in \mathcal{X}^n$ (Fig. 2.1). O codificador descreve X^n através de um índice $i \in \mathcal{I}$, enquanto o decodificador traduz i em uma seqüência de reprodução $\hat{X}^n \in \hat{\mathcal{X}}^n$. A *distorção* introduzida pelo código é definida como

$$D = E[d(X^n, \hat{X}^n)] = E[d(X^n, \beta(\alpha(X^n)))]. \quad (2-6)$$

Diz-se que o código tem *taxa* R bits por símbolo da fonte no sentido de que $\log M = nR$ bits são suficientes para representar o índice $i \in \{1, \dots, M\}$ de cada palavra codificada.

Estamos interessados em construir códigos que sejam bons do ponto de vista do compromisso taxa-distorção, isto é, códigos que, para uma dada taxa R , produzem a menor distorção possível, ou inversamente, para uma dada distorção D , requerem a menor taxa possível. É conveniente definir uma função que expresse o limite prático dessa busca por códigos, isto é, uma função que expresse a menor taxa R que pode ser atingida por um código em função da distorção tolerada D .

Definição 2.5 (Função Taxa-Distorção Operacional) A mínima taxa admissível para um código com distorção não superior a D é denotada por $R^*(D)$ e é chamada *função taxa-distorção operacional*. Isto significa que, se uma máxima distorção tolerável D é especificada, então é sempre possível encontrar um código que realize uma compressão a uma taxa superior mas arbitrariamente próxima de $R^*(D)$, enquanto, reciprocamente, é impossível encontrar um código com taxa R inferior a $R^*(D)$. Se todos os pares taxa-distorção (R, D) forem dispostos em um gráfico $R \times D$, então a função taxa-distorção operacional divide o plano em uma região superior admissível (onde códigos com distorção D e taxa $R > R^*(D)$ existem) e uma região inferior em que não existem códigos com distorção D e taxa $R < R^*(D)$.

O problema básico da teoria taxa-distorção é, dada a distribuição da fonte e a medida de distorção, determinar a função $R^*(D)$. O principal resultado dessa teoria, conhecido como Teorema da Compressão de Fontes (Shannon, 1959 [30]), fornece uma expressão matemática para essa função. A seguir, são apresentadas algumas definições que subsidiam o teorema. Por simplicidade, os conceitos apresentados se referem apenas a variáveis aleatórias discretas, mas ressaltamos que existem versões análogas para variáveis aleatórias contínuas [1].

Definição 2.6 (Entropia) Seja X uma variável aleatória discreta que assume valores no conjunto \mathcal{X} de acordo com uma distribuição de probabilidade $P(x)$, $x \in \mathcal{X}$. A *entropia* de X é definida como

$$H(X) = - \sum_{x \in \mathcal{X}} P(x) \log P(x). \quad (2-7)$$

Definição 2.7 (Entropia Condicional e Informação Mútua) Sejam X e Y variáveis aleatórias discretas com distribuição conjunta $P(x, y)$, $x \in \mathcal{X}$, $y \in \mathcal{Y}$, e distribuições marginais $P(x)$ e $P(y)$, respectivamente. A *entropia condicional* de X dado Y é

$$H(X|Y) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P(x, y) \log P(x|y) \quad (2-8)$$

e a *informação mútua* entre X e Y é

$$I(X; Y) = H(X) - H(X|Y) = \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P(x, y) \log \frac{P(x, y)}{P(x)P(y)}. \quad (2-9)$$

Definição 2.8 (Função Taxa-Distorção) A *função taxa-distorção* para uma fonte discreta sem memória X com distribuição $P(x)$ e medida de distorção $d(x, \hat{x})$ é definida como

$$R(D) = \min_{P(\hat{x}|x): \sum_{(x, \hat{x})} P(x)P(\hat{x}|x)d(x, \hat{x}) \leq D} I(X; \hat{X}) \quad (2-10)$$

onde a minimização é realizada sobre todas as distribuições condicionais $P(\hat{x}|x)$ que satisfazem a restrição no valor esperado da distorção $d(x, \hat{x})$.

Teorema 2.1 (Teorema da Compressão de Fontes) A função taxa-distorção operacional para uma fonte discreta sem memória X com distribuição $P(x)$ e medida de distorção $d(x, \hat{x})$ é igual à função taxa-distorção associada. Ou seja,

$$R^*(D) = \min_{P(\hat{x}|x): \sum_{(x, \hat{x})} P(x)P(\hat{x}|x)d(x, \hat{x}) \leq D} I(X; \hat{X}) = R(D) \quad (2-11)$$

é a mínima taxa admissível para um código com distorção D .

2.2

Cálculo da Função Taxa-Distorção

O cálculo da função $R(D)$ é um problema variacional que envolve uma minimização com restrição de uma função logarítmica. Apesar de conhecida em alguns casos simples, a expressão analítica para a função taxa-distorção é desconhecida na maioria das situações. Na prática, a curva da função $R(D)$ pode ser obtida numericamente utilizando-se o conhecido algoritmo de Blahut [6], o qual é descrito no Apêndice A. Este algoritmo, apesar de definido para fontes discretas, é também capaz de encontrar a função $R(D)$ de uma fonte contínua. Para esse fim, é necessário que a fonte seja discretizada com suficiente precisão [13], isto é, tanto \mathcal{X} quanto $\hat{\mathcal{X}}$ devem ser versões quantizadas dos alfabetos originais.

A seguir são apresentadas curvas da função $R(D)$ para algumas fontes de interesse neste trabalho. Em todos os casos, consideramos a medida de distorção de erro quadrático (Eq. (2-2)).

Fonte uniforme

Considere uma fonte sem memória com função densidade de probabilidade uniforme dada por

$$f(x) = \begin{cases} 1 & -\frac{1}{2} \leq x \leq \frac{1}{2} \\ 0 & \text{c.c.} \end{cases} \quad (2-12)$$

Esta função é também mostrada na Fig. 2.2.

O gráfico da função taxa-distorção para esta fonte, obtido numericamente com o algoritmo de Blahut, é mostrado na Fig. 2.3.

Fonte gaussiana

Considere uma fonte sem memória com função densidade de probabilidade gaussiana dada por

$$f(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{x^2}{2\sigma^2}} \quad (2-13)$$

onde σ^2 é a variância da fonte. O gráfico dessa função para $\sigma = 1$ está mostrado na Fig. 2.4.

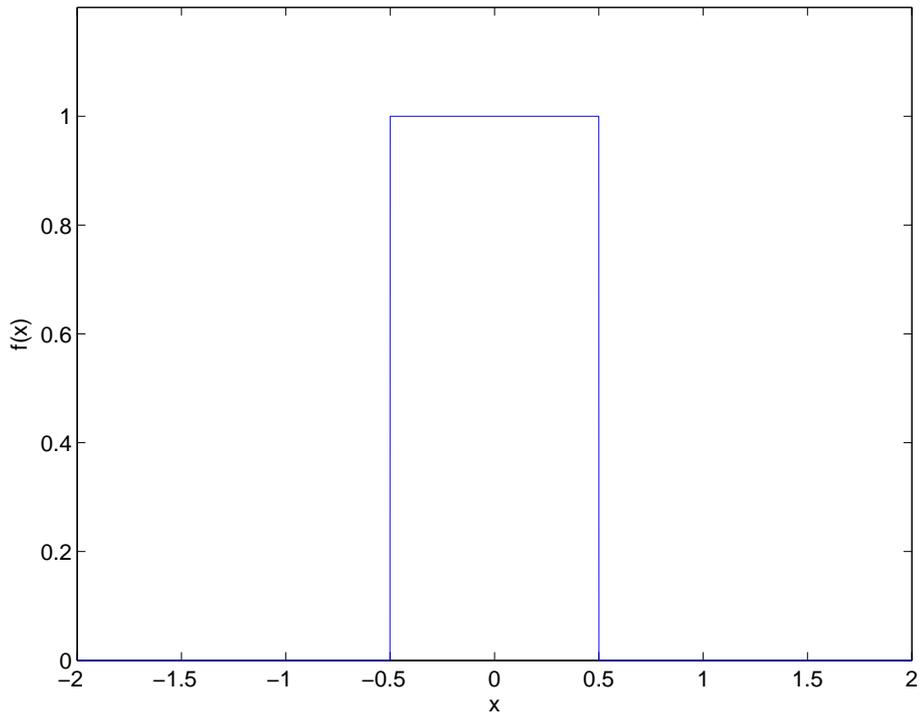


Figura 2.2: Função densidade de probabilidade de uma fonte uniforme.

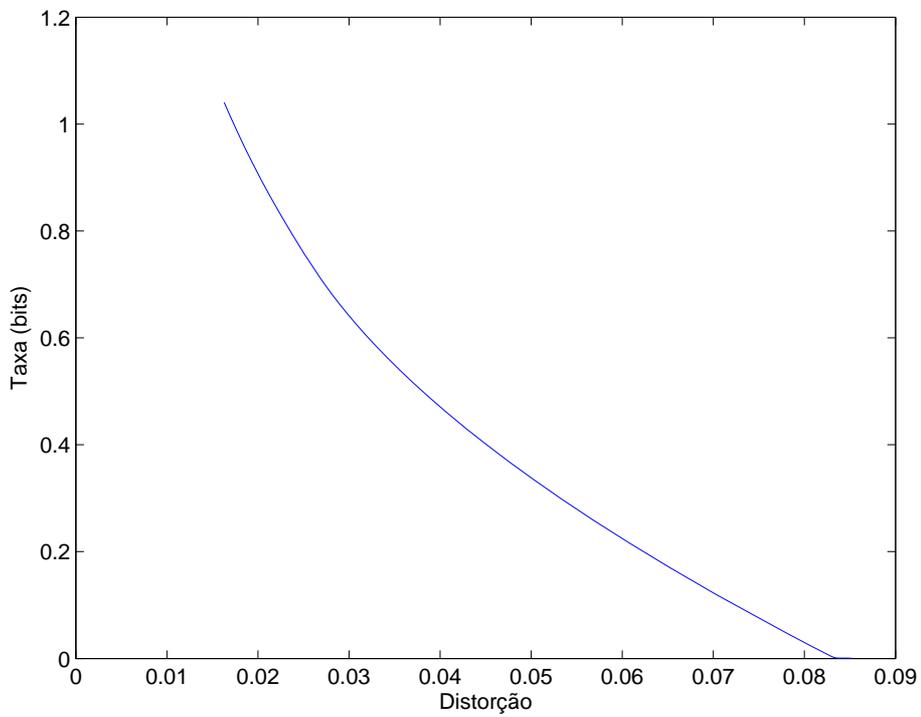


Figura 2.3: Função taxa-distorção para uma fonte uniforme.

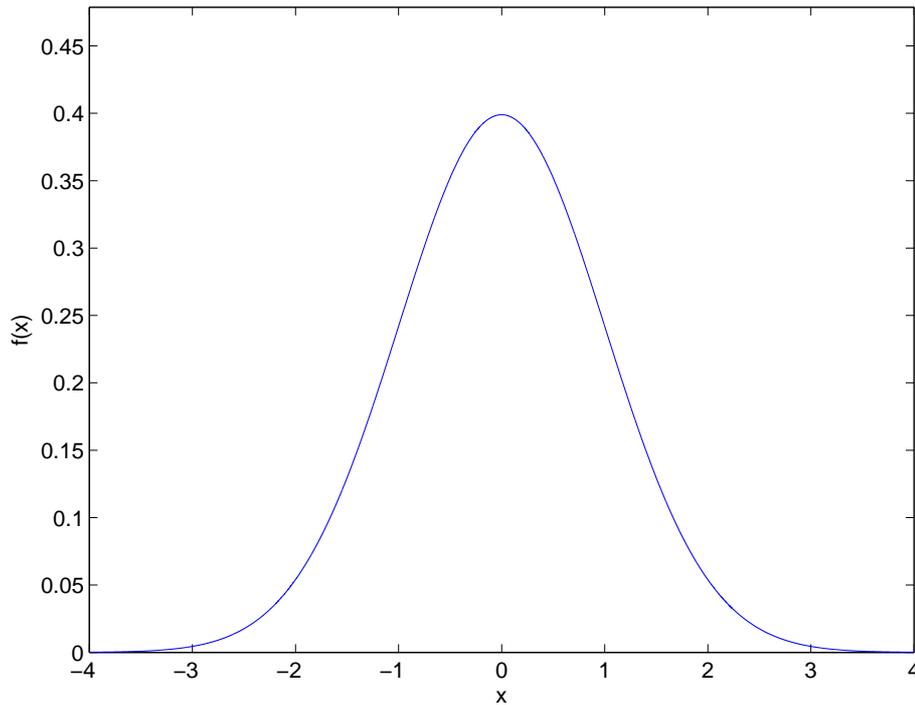


Figura 2.4: Função densidade de probabilidade de uma fonte gaussiana.

A função $R(D)$ para esta fonte tem expressão analítica conhecida:

$$R(D) = \begin{cases} \frac{1}{2} \log \frac{\sigma^2}{D} & 0 \leq D \leq \sigma^2 \\ 0 & D \geq \sigma^2. \end{cases} \quad (2-14)$$

Na Fig. 2.5, apresentamos a curva desta função considerando $\sigma = 1$.

Fonte laplaciana

Considere uma fonte sem memória com função densidade de probabilidade laplaciana dada por

$$f(x) = \frac{1}{2} e^{-|x|}. \quad (2-15)$$

Esta função está esboçada na Fig. 2.6.

O gráfico da função taxa-distorção para esta fonte, obtido numericamente com o algoritmo de Blahut, é mostrado na Fig. 2.7.

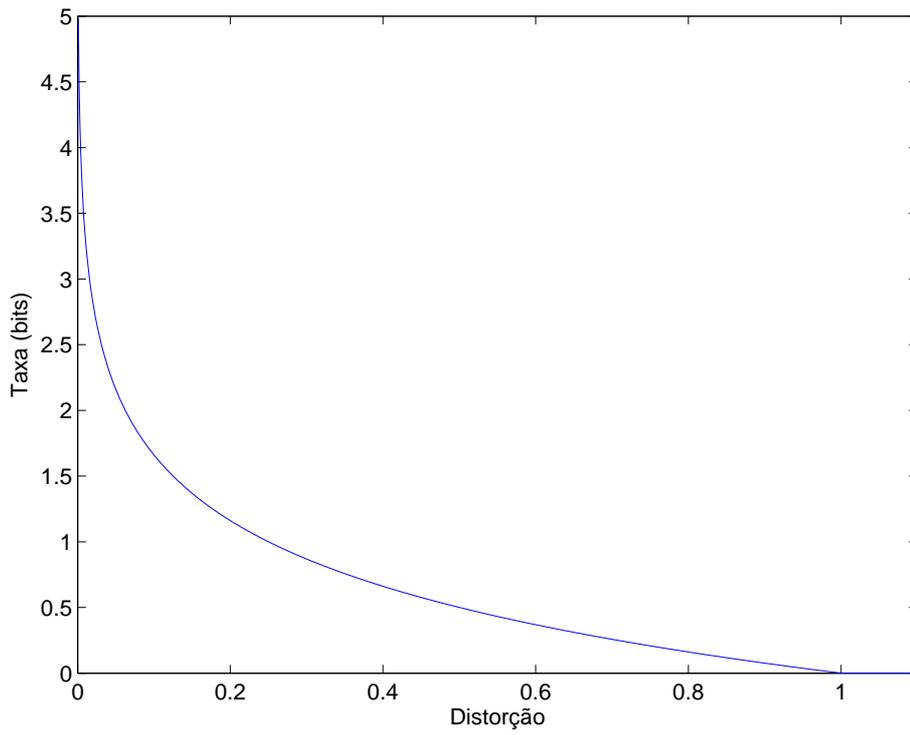


Figura 2.5: Função taxa-distorção para uma fonte gaussiana.

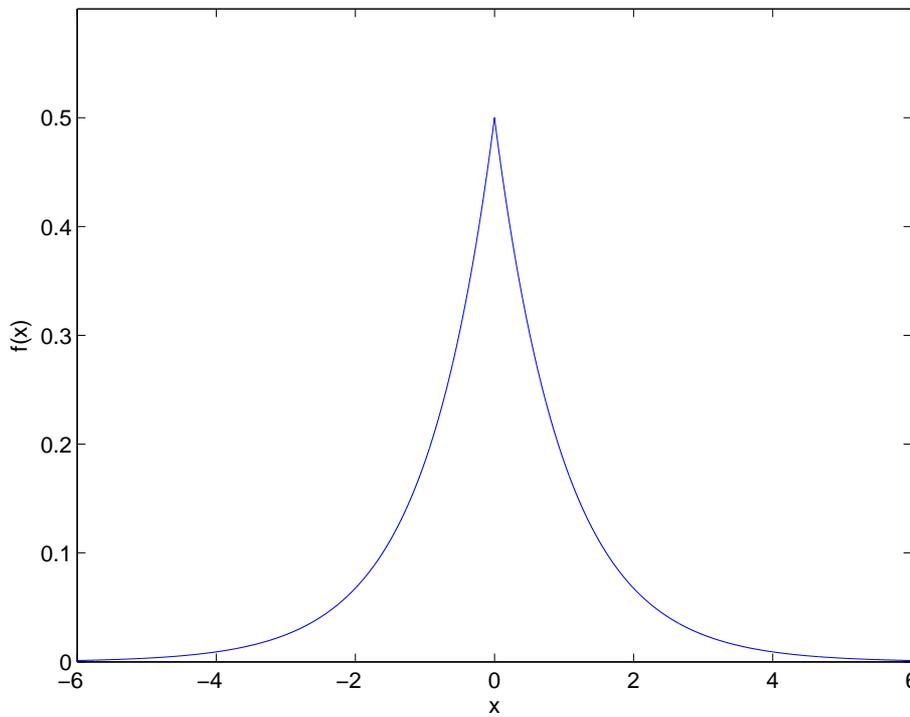


Figura 2.6: Função densidade de probabilidade de uma fonte laplaciana.

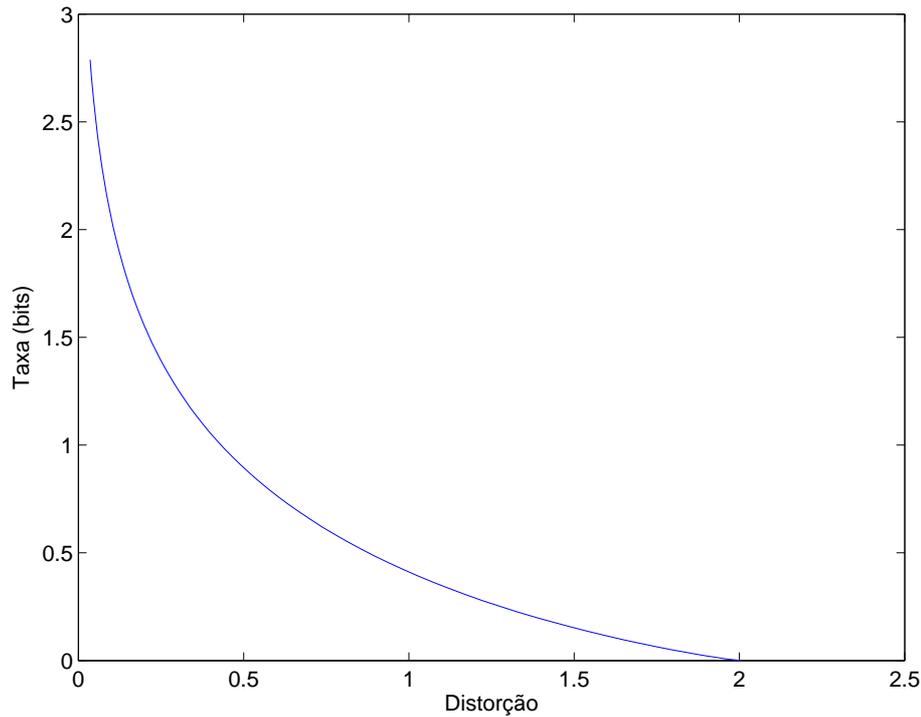


Figura 2.7: Função taxa-distorção para uma fonte laplaciana.

2.3 Quantização

Um quantizador consiste de um código de bloco para compressão concatenado com um código de fonte sem perdas, onde este último converte os índices produzidos em dígitos binários, com o objetivo de transmití-los através de um canal. O código sem perdas pode ser tanto de taxa fixa como de taxa variável. No primeiro caso, os índices i são convertidos em palavras binárias de comprimento fixo (como implicitamente sugerido pela teoria taxa-distorção), enquanto no segundo caso os comprimentos das palavras binárias podem ser diferentes. A justificativa para essa última abordagem reside na observação prática de que os índices i em geral têm probabilidades significativamente diferentes, o que sugere que uma codificação de taxa variável pode resultar em menor redundância que a codificação de taxa fixa, idealmente atingindo taxas próximas à entropia dos índices. Assim, este tipo de codificação em um quantizador é também chamado de *codificação de entropia*.

Ressaltamos que a função taxa-distorção é também o limitante quando se usa codificação de taxa variável. Assim, se o tamanho de bloco $n \rightarrow \infty$, é suficiente considerar a codificação de taxa fixa pois nenhum ganho adicional pode ser obtido com a codificação de taxa variável. Por outro lado, se n é finito, ganhos significativos podem geralmente ser obtidos ao se permitir

uma taxa variável na codificação sem perdas.

Usualmente, os quantizadores são utilizados para compressão de uma fonte cujo alfabeto é o conjunto dos números reais. Uma definição de quantizador é apresentada a seguir.

Definição 2.9 (Quantizador) Seja o conjunto $\mathcal{I} = \{1, 2, \dots, M\}$. Um *quantizador* de dimensão n consiste de três componentes (Fig. 2.8): um *codificador com perdas*

$$\alpha : \mathbb{R}^n \rightarrow \mathcal{I} \quad (2-16)$$

que mapeia um vetor n -dimensional $\mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$ em um índice $i \in \mathcal{I}$; um *decodificador de reprodução*

$$\beta : \mathcal{I} \rightarrow \mathbb{R}^n \quad (2-17)$$

que mapeia um índice $i \in \mathcal{I}$ em um vetor $\hat{\mathbf{x}} = (\hat{x}_1, \dots, \hat{x}_n) \in \mathbb{R}^n$; e um *codificador sem perdas*

$$\gamma : \mathcal{I} \rightarrow \mathcal{V} \quad (2-18)$$

que mapeia de forma biunívoca um índice $i \in \mathcal{I}$ em uma palavra binária de um conjunto $\mathcal{V} \subset \{0, 1\}^*$, onde \mathcal{V} é um código instantâneo [11] formado por palavras binárias de comprimentos arbitrários.¹

Alternativamente, um quantizador pode ser especificado por: uma partição de \mathbb{R}^n

$$\mathcal{S} = \{\mathcal{S}_i, i \in \mathcal{I}\} \quad (2-19)$$

onde cada $\mathcal{S}_i = \{\mathbf{x} : \alpha(\mathbf{x}) = i\}$ é uma *região de decisão* ou *célula*; um *dicionário (de reprodução)*

$$\mathcal{C} = \{\mathbf{y}_i, i \in \mathcal{I}\} \quad (2-20)$$

onde cada $\mathbf{y}_i = \beta(i)$ é uma *palavra de reprodução*; e um dicionário

$$\mathcal{V} = \{v_i, i \in \mathcal{I}\} \quad (2-21)$$

onde cada $v_i = \gamma(i)$ é uma palavra binária.

Se $n = 1$ o quantizador é dito *escalar*; caso contrário, é *vetorial*. Se todas as palavras binárias em \mathcal{V} têm o mesmo comprimento, diz-se que o quantizador tem *taxa fixa*; caso contrário, tem *taxa variável*.

O quantizador é aplicado ao vetor da fonte $\mathbf{X} = (X_1, \dots, X_n) \in \mathbb{R}^n$, o qual é reproduzido na saída como o vetor $\hat{\mathbf{X}} = (\hat{X}_1, \dots, \hat{X}_n)$. A distorção

¹A notação $\{0, 1\}^* = \{0, 1, 00, 01, 10, 11, \dots\}$ é usada para representar o conjunto de todas as palavras binárias de quaisquer comprimentos.

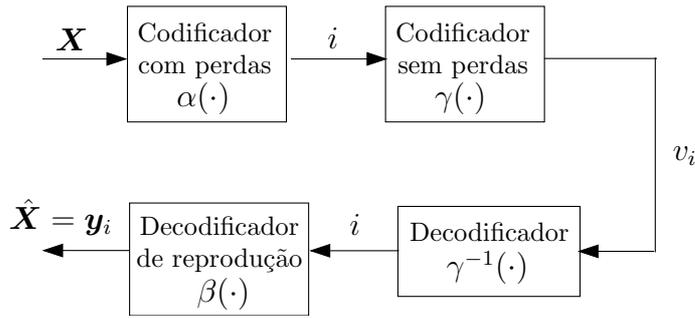


Figura 2.8: Quantizador.

associada ao quantizador é definida como

$$D = E[d(\mathbf{X}, \hat{\mathbf{X}})] = E[d(\mathbf{X}, \beta(\alpha(\mathbf{X})))] \quad (2-22)$$

e a taxa do quantizador, em bits por símbolo da fonte, é definida como

$$R = E\left[\frac{1}{n} |\gamma(\alpha(\mathbf{X}))|\right] = \frac{1}{n} \sum_{i=1}^M p_i |\gamma(i)| = \frac{1}{n} \sum_{i=1}^M p_i \ell_i \quad (2-23)$$

onde $p_i = P(\alpha(\mathbf{X}) = i) = P(\mathbf{X} \in S_i)$ é a probabilidade de ocorrência da célula S_i , e $\ell_i = |v_i|$ é o comprimento da palavra binária associada.

O projeto de um quantizador tem como objetivo otimizar o compromisso entre taxa e distorção. Este compromisso ótimo entre taxa e distorção pode ser formalizado de três maneiras equivalentes: como uma otimização da taxa dada uma restrição na distorção, como uma otimização da distorção dada uma restrição na taxa, ou ainda como a otimização de um lagrangiano envolvendo taxa e distorção. Nesta última abordagem, a função objetivo que se deseja minimizar é expressa como

$$J_\lambda(\alpha, \beta, v) = D(\alpha, \beta) + \lambda R(\alpha, v) \quad (2-24)$$

onde λ é um número real não-negativo. Um baixo valor de λ leva a soluções de baixa distorção e alta taxa, enquanto um alto valor de λ leva a soluções de baixa taxa e alta distorção.

Não existe solução geral fechada para este problema. É possível, no entanto, encontrar algumas *condições de otimalidade* do quantizador, isto é, condições que precisam ser satisfeitas para que o quantizador seja ótimo. Estas propriedades de um quantizador ótimo são sumarizadas a seguir:

- Para um codificador com perdas α fixo, independentemente do codificador sem perdas γ , o decodificador de reprodução ótimo β é dado

pelos palavras de reprodução que minimizam a distorção condicional sobre as respectivas regiões de decisão, isto é, por

$$\beta(i) = \arg \min_{\mathbf{y} \in \mathbb{R}^n} E[d(\mathbf{X}, \mathbf{y}) | \alpha(\mathbf{X}) = i], \quad i = 1, \dots, M. \quad (2-25)$$

Diz-se que $\beta(i)$ é o *centróide* da célula $\mathcal{S}_i = \{\mathbf{x} : \alpha(\mathbf{x}) = i\}$. Se a medida de distorção é de erro quadrático, então o centróide de \mathcal{S}_i é simplesmente o valor esperado dos vetores $\mathbf{X} \in \mathcal{S}_i$:

$$\beta(i) = E[\mathbf{X} | \alpha(\mathbf{X}) = i]. \quad (2-26)$$

- Para um codificador com perdas α fixo, independentemente do decodificador de reprodução β , o codificador sem perdas ótimo γ é dado pelo código sem perdas ótimo para a fonte discreta $\alpha(\mathbf{X})$, por exemplo, um código de Huffman para esta fonte. Note que $\alpha(\mathbf{X})$ é a fonte cujos símbolos são os índices i produzidos pelo codificador com perdas, os quais têm probabilidade de ocorrência dada por

$$p_i = P(\alpha(\mathbf{X}) = i) = E[\mathbb{1}(\alpha(\mathbf{X}) = i)] \quad (2-27)$$

onde $\mathbb{1}(\cdot)$ é a *função verdade* ou *função indicadora*.²

- Para um decodificador de reprodução β , um codificador sem perdas γ , e um parâmetro lagrangiano λ fixos, o codificador com perdas ótimo é um codificador de mínima distorção (vizinho-mais-próximo) para a medida de distorção lagrangiana modificada

$$\alpha(\mathbf{x}) = \arg \min_{i \in \mathcal{I}} [d(\mathbf{x}, \beta(i)) + \lambda|\gamma(i)|]. \quad (2-28)$$

Note que quando o quantizador é restrito a uma taxa fixa, todas as palavras binárias v_i têm o mesmo comprimento e portanto γ se reduz simplesmente a uma indexação binária de \mathcal{I} . Assim, a segunda propriedade acima se torna irrelevante, e na terceira propriedade a parcela que envolve γ pode ser eliminada.

As condições acima nos permitem construir um algoritmo iterativo para o projeto de quantizadores: dado o parâmetro λ e um quantizador inicial (α, β, γ) , otimiza-se sequencialmente os componentes α , β e γ , considerando para cada um deles os componentes restantes fixos. Este

²A *função indicadora* é definida como $\mathbb{1}(B) = \begin{cases} 1 & \text{se a proposição } B \text{ é verdadeira} \\ 0 & \text{se a proposição } B \text{ é falsa.} \end{cases}$

processo então é repetido, reduzindo o lagrangiano (2-24) a cada etapa, até que seja atingido um ótimo local ou global.

O algoritmo descrito acima foi proposto por Lloyd para quantização escalar de taxa fixa em 1957 [26], e estendido para vetores e popularizado por Linde, Buzo e Gray em 1980 [25], sendo conhecido como *algoritmo de Lloyd generalizado* ou *algoritmo LBG*. A formulação lagrangiana do algoritmo foi primeiro proposta por Berger em 1972 [3] e posteriormente generalizada para vetores por Chou *et al.* em 1989 [9].

Note que a aplicação do algoritmo exige o cálculo dos valores esperados em (2-26) e (2-27). A não ser para dimensões n pequenas, esta operação se torna extremamente complexa e dispendiosa do ponto de vista computacional pois requer que seja realizada uma integração em n dimensões. A abordagem mais comum para esse problema é substituir o valor esperado por uma média amostral, isto é, o valor esperado de uma variável aleatória é estimado como a média aritmética de uma seqüência de amostras independentes dessa variável. Como todas as variáveis de interesse são funções do vetor aleatório \mathbf{X} , é suficiente dispor de uma seqüência de amostras desse vetor (ou seja, da fonte). Esta seqüência, quando utilizada no projeto de quantizadores, é geralmente chamada de *seqüência de treinamento*; quando usada na avaliação de desempenho, para o cálculo da distorção em (2-22), é chamada de *seqüência de teste*. Note que esta abordagem é particularmente útil no caso em que a distribuição da fonte é desconhecida, por exemplo, na compressão de dados reais. A justificativa para a substituição do valor esperado por uma estimativa através de seqüências amostrais é melhor desenvolvida no Apêndice B.

2.4

Quantização de Taxa Fixa

Nesta seção particularizamos o desenvolvimento da seção anterior para quantizadores de taxa fixa. Como apontado anteriormente, em quantizadores de taxa fixa o codificador sem perdas γ se torna trivial. Assim, dados a dimensão n e o número de palavras de reprodução M , um quantizador de taxa fixa com codificação ótima pode ser completamente especificado através de seu dicionário de reprodução $\mathcal{C} = \{\mathbf{y}_i\}_{i=1}^M$, enquanto a regra de codificação ótima (mínima distorção) é dada simplesmente por

$$\alpha(\mathbf{x}) = \arg \min_{i \in \mathcal{I}} d(\mathbf{x}, \mathbf{y}_i). \quad (2-29)$$

Se M é uma potência de 2, é sempre possível codificar sem perdas os M índices $i \in \mathcal{I}$ através de um código binário de comprimento fixo $\ell_i = \log M$. Se M não é uma potência de 2, a indexação requer $\ell_i = \lceil \log M \rceil$ bits. Independentemente de M , no entanto, definimos a taxa como

$$R = \frac{1}{n} \log M. \quad (2-30)$$

Existem várias justificativas para se usar essa definição ao invés da definição mais rigorosa $R' = n^{-1} \lceil \log M \rceil$. Em primeiro lugar, a taxa R pode ser alcançada codificando-se conjuntamente um grupo de 2 ou mais índices consecutivos [17]. Para n grande, mesmo esse procedimento é desnecessário pois a diferença $R' - R < 1/n$ torna-se desprezível. Além disso, estamos interessados em analisar o desempenho teórico de quantizadores, e a definição em (2-30) mostra-se mais adequada à análise.

Um quantizador de taxa fixa com medida de distorção de erro quadrático é conhecido como *quantizador de mínimo erro médio quadrático* (MMSE), ou *quantizador Lloyd-Max* no caso escalar. O algoritmo de projeto para esse tipo de quantizador é explicitado a seguir.

Algoritmo 2.1 (Projeto de Quantizador MMSE)

- 1) Especifique a dimensão n , o tamanho do dicionário M e o dicionário inicial $\{\mathbf{y}_i\}_{i=1}^M$.
- 2) Defina $\alpha(\mathbf{x}) = \arg \min_i d(\mathbf{x}, \mathbf{y}_i)$.
- 3) Calcule $\mathbf{y}_i = E[\mathbf{X} | \alpha(\mathbf{X}) = i]$, $i = 1, \dots, M$.
- 4) Volte para o passo 2 até que $\{\mathbf{y}_i\}_{i=1}^M$ convirja.
- 5) Fim. ■

2.5

Quantização com Restrição de Entropia

Nesta seção retornamos o desenvolvimento da Seção 2.3 para quantizadores sem a restrição de taxa fixa. Dados a dimensão n e o número de palavras de reprodução M , um quantizador genérico com codificação ótima pode ser completamente especificado através do dicionário de reprodução $\mathcal{C} = \{\mathbf{y}_i\}_{i=1}^M$, das palavras binárias v_i , $i = 1, \dots, M$, e da regra de codificação ótima

$$\alpha(\mathbf{x}) = \arg \min_{i \in \mathcal{I}} [d(\mathbf{x}, \mathbf{y}_i) + \lambda |v_i|]. \quad (2-31)$$

Como a restrição é imposta aos comprimentos das palavras binárias v_i , os quais normalmente estão ligados às probabilidades dos índices i e conseqüentemente à sua entropia, este tipo de quantizador é chamado de *quantizador com restrição de entropia*, sendo denotado por ECVQ (*entropy-constrained vector quantizer*) no caso vetorial e por ECSQ (*entropy-constrained scalar quantizer*) no caso escalar.

Para fins de análise e projeto, é útil considerar que se dispõe de um codificador de entropia “ideal”, isto é, formado por palavras v_i de comprimentos fracionários

$$|v_i| = \log(1/p_i) \quad (2-32)$$

onde $p_i = P(\alpha(\mathbf{X}) = i)$. Nesse caso, a “taxa” do quantizador resultante³ é exatamente igual à entropia da fonte $\alpha(\mathbf{X})$:

$$R = \sum_{i=1}^M p_i \log(1/p_i) = H(\alpha(\mathbf{X})). \quad (2-33)$$

Essa abordagem tem a vantagem adicional de não atar o quantizador obtido a um codificador de entropia específico.

O algoritmo para projeto de um ECVQ com medida de distorção de erro quadrático é explicitado a seguir.

Algoritmo 2.2 (Projeto de ECVQ)

- 1) Especifique a dimensão n , o tamanho do dicionário M , o dicionário inicial $\{\mathbf{y}_i\}_{i=1}^M$ e o parâmetro lagrangiano λ .
- 2) Inicialize $p_i = 1/M$, $i = 1 \dots M$.
- 3) Defina $\alpha(\mathbf{x}) = \arg \min_i [d(\mathbf{x}, \mathbf{y}_i) + \lambda \log(1/p_i)]$.
- 4) Calcule $\mathbf{y}_i = E[\mathbf{X} | \alpha(\mathbf{X}) = i]$, $i = 1, \dots, M$.
- 5) Calcule $p_i = E[\mathbf{1}(\alpha(\mathbf{X}) = i)]$, $i = 1, \dots, M$.
- 6) Volte para o passo 3 até que $\{\mathbf{y}_i\}_{i=1}^M$ convirja.
- 7) Fim. ■

Dependendo do valor de λ escolhido, é possível que em alguma iteração do algoritmo nenhum vetor da fonte seja associado a uma certa região

³Note que a taxa R' de um código de Huffman satisfaz a cota [9]

$$R \leq R' \leq R + \max_i p_i + 0.086.$$

de decisão. Descarta-se então a palavra de reprodução correspondente, reduzindo-se de uma unidade o parâmetro M , e as iterações continuam. Na operação geral do algoritmo, inicia-se com o menor λ de interesse (ex: $\lambda = 0$) e o maior M possível dentro das limitações de complexidade. A cada projeto finalizado, λ é gradativamente aumentado, acarretando eventualmente a redução de M , e o quantizador obtido é utilizado como ponto de partida do projeto seguinte. Quando $\lambda = 0$, o algoritmo se reduz ao do projeto de quantizadores de mínima distorção; quando $\lambda \rightarrow \infty$ ($M = 1$), o quantizador resultante é trivial e tem taxa $R = 0$. Este procedimento nos permite traçar uma curva de operação $R \times D$ para um ECVQ semelhante às curvas mostradas nas figuras 2.3, 2.5 e 2.7.

Apesar de mais poderosos que os de taxa fixa, os quantizadores de taxa variável possuem a séria desvantagem prática de precisar lidar com o número variável de bits produzidos [18]. Por exemplo, para se transmitir esses bits através de um canal de comunicação de taxa fixa, é preciso utilizar um buffer e lidar com os problemas de *overflow* e *underflow* de buffer que podem ocorrer. Outra desvantagem é o potencial para propagação de erros quando alguns bits são recebidos com erro (canal não-ideal). Os problemas causados pela variabilidade da taxa podem ser proibitivos para muitas aplicações, exigindo o uso de estratégias complexas para minimizar seus efeitos. Este motivo, combinado ao fato de que a codificação de entropia é geralmente uma etapa significativamente complexa, justifica a busca de quantizadores de taxa fixa com maior dimensão e menor complexidade total.

Os quantizadores apresentados neste capítulo são conhecidos como quantizadores *não-estruturados*, isto é, permite-se que as palavras de reprodução sejam escolhidas com total liberdade em \mathbb{R}^n . Uma outra classe de interesse é a de quantizadores *estruturados*, onde é imposta uma estrutura em algum componente do quantizador, por exemplo, na geração do dicionário. Esta abordagem resulta geralmente em códigos sub-ótimos para sua dimensão, porém com implementação mais eficiente ou com outras vantagens práticas. Um exemplo de quantizador vetorial estruturado é apresentado no próximo capítulo.