



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA  
UNIDADE ACADÊMICA DE ENGENHARIA ELÉTRICA

Trabalho de Conclusão de Curso

**Estudo e Aplicação de Técnicas de Compressão Para Imagens  
Digitais Coloridas**

**Vinícius Magno Uchôa Lima Oliveira**

**Prof. Dr. Waslon Terllizzie Araújo Lopes**

Professor Orientador

Campina Grande, Fevereiro de 2012

**Universidade Federal de Campina Grande**

Vinícius Magno Uchôa Lima Oliveira

**Estudo e Aplicação de Técnicas de Compressão Para  
Imagens Digitais Coloridas**

Trabalho de Conclusão de Curso apresentado à  
Unidade Acadêmica de Engenharia Elétrica  
como parte dos requisitos para obtenção do  
título de Engenheiro Eletricista.

Orientador

Prof. Dr. Waslon Terllizzie Araújo Lopes

Campina Grande, Fevereiro de 2012

## Agradecimentos

Dedico este trabalho a todos que contribuíram para sua realização.

Agradeço a minha maravilhosa família, em especial meus pais Antonio Uchoa e Rosane pela vida, ensinamentos, por me ter permitido escolher o bom caminho e pelo amor imensurável. Meus irmãos Rostonio e Gabriela pelo amor, ambiente familiar, o apoio e amizade. Minha madrinha Solange pelos conselhos, o carinho e apoio. Todos vocês são meus exemplos a seguir.

Agradeço minha namorada Fabiana pelo amor, apoio, compreensão, confiança, paciência, seu exemplo que me faz ter orgulho de viver a seu lado. Agradeço também a Francisco e Cleide pelo apoio e por me acolher tão bem como família longe da minha família.

Agradeço com imenso prazer:

- Aos colegas: Alysson, Ayslan, Gregory, Juan, Letícia e Victor.
- Aos mestres Waslon Terllizzie, Edmar Gurjão, Francisco Tejo, Bruno Albert e Glauco Fontgalland.

## Resumo

Com os avanços tecnológicos, é crescente o volume de informações ao passo que os sistemas de armazenamento e transmissão não acompanham tal demanda. Reside nesse fato a importância da compressão de dados. O presente trabalho apresenta um estudo comparativo entre duas técnicas de compressão para imagens coloridas: DCT (do inglês *Discrete Cosine Transform*) e Quantização Vetorial. Apesar de serem técnicas clássicas, estão presentes nos mais modernos codificadores de vídeo. Foram implementados algoritmos para as duas técnicas e realizadas simulações em imagens bastante conhecidas no âmbito do processamento digital. Os resultados demonstraram que é possível comprimir imagens de forma simples e foram apresentados as diferenças de comportamento entre os dois métodos.

**Palavras-chave:** Compressão de imagens, DCT, Quantização Vetorial

## Lista de Ilustrações

Figura 2.1 Imagem digitalizada com resolução espacial 8x9 e sua respectiva representação matricial com 256 níveis de cinza.....	3
Figura 2.2 (a) Exemplo de imagem contínua (b) Resultado de uma amostragem e quantização.....	4
Figura 2.3 (a) Representação de uma mesma cena para as seguintes resoluções: (a) 280x280 pixels (b) 140x140 pixels (c) 70x70 pixels .....	4
Figura 2.4 (a) Representação de uma mesma cena a (a) 4 bits (16 tons); (b) 3 bits (8 tons) e (c) 1 bit (2 tons) respectivamente.....	5
Figura 2.5 (a) Padrão de cores aditivo RGB. (b) Cubo esquemático para o padrão RGB .....	5
Figura 2.6 Contribuição de cada componente de cor na representação da imagem Tulipas, (a) Vermelho (R); (b) Verde (G); (c) Azul (B); (d) Imagem colorida.....	6
Figura 2.7 Uma função arbitrária $f(t)$ analisada pela soma de funções harmônicas de diferentes frequências e amplitudes complexas.....	8
Figura 2.8 Imagem representada por uma soma de funções harmônicas de diferentes frequências e amplitudes complexas após aplicação da transformada de Fourier. As partes brancas representam picos positivos e as pretas, picos negativos. (Extraída de [4]) .....	8
Figura 2.9 (a) As 64 funções base da DCT 8x8. As frequências horizontais crescem da esquerda para a direita enquanto as frequências verticais crescem de cima para baixo. Na posição (0,0) tem-se a função base de valor constante chamada de função base DC e seu coeficiente correspondente é conhecido como coeficiente DC. (b) Distribuição de frequência para o bloco 8x8.....	9
Figura 2.10 (a) Imagem Mandrill (b) Imagem em 8x8 pixels relativa ao bloco detalhado em preto na imagem em (a); (c) valores dos pixels relativos ao bloco.....	10
Figura 2.11 Algumas Máscaras de Quantização do padrão JPEG. Cada valor no espectro da DCT é dividido pelo valor correspondente na máscara de quantização e arredondado.....	11
Figura 2.12 Representação da Quantização Vetorial. [Adaptado de [8]]. .....	12
Figura 2.13 Partição do espaço bidimensional em 18 células ( $N = 18$ ). Todos os vetores de entrada na célula $R_i$ serão quantizados como $y_i$ . .....	12
Figura 2.14 Etapas do processo de geração de um dicionário. Adaptado de [10].....	13
Figura 3.1 Máscaras correspondentes às 4 transformações realizadas: (a) 4 Coeficientes; (b) 10 Coeficientes; (c) 36 Coeficientes; (d) 56 Coeficientes.....	16
Figura 3.2 Imagem base para treinamento de dicionários utilizando algoritmo LBG.	17
Figura 4.1 Curvas dos valores de PSNR em função da taxa de compressão resultantes da aplicação da DCT 8x8.....	19
Figura 4.2 Imagem Monalisa para (a) 4 Coeficientes (b) 10 Coeficientes (c) 36 Coeficientes (d) 56 Coeficientes .....	19

Figura 4.3 Imagem Lena para (a) 4 Coeficientes (b) 10 Coeficientes (c) 36 Coeficientes (d) 56 Coeficientes .....	19
Figura 4.4 Imagem Mandrill para (a) 4 Coeficientes (b) 10 Coeficientes (c) 36 Coeficientes (d) 56 Coeficientes .....	20
Figura 4.5 Curvas dos valores de PSNR em função da taxa de compressão resultantes da aplicação da Quantização Vetorial.....	21
Figura 4.6 Imagem Monalisa reconstruída utilizando dicionários com as respectivas quantidades de níveis: (a) 32 Níveis (b) 64 Níveis (c) 128 Níveis (d) 256 Níveis (e) 512 Níveis; (f) Imagem original para comparação.....	22
Figura 4.7 Imagem Lena para reconstruída utilizando dicionários com as respectivas quantidades de níveis: (a) 32 Níveis (b) 64 Níveis (c) 128 Níveis (d) 256 Níveis (e) 512 Níveis; (f) Imagem original para comparação.....	22
Figura 4.8 Imagem Mandrill para reconstruída utilizando dicionários com as respectivas quantidades de níveis: (a) 32 Níveis (b) 64 Níveis (c) 128 Níveis (d) 256 Níveis (e) 512 Níveis; (f) Imagem original para comparação.....	23

## Lista de Tabelas

Tabela 2.1 Valores dos pixels correspondentes ao bloco 8x8 detalhado na Figura 2.10a .....	10
Tabela 2.2 Coeficientes após aplicação da DCT sobre o bloco 8x8 correspondente à Tabela 2.1.....	10
Tabela 2.3 Notas para critério de avaliação subjetivo da " <i>Television Allocations Study Organization</i> " .....	14
Tabela 4.1 Resultados obtidos após aplicação da DCT sobre a imagem Monalisa.....	18
Tabela 4.2 Resultados obtidos após aplicação da DCT sobre a imagem Lena .....	18
Tabela 4.3 Resultados obtidos após aplicação da DCT sobre a imagem Mandrill.....	18
Tabela 4.4 Resultados obtidos após aplicação da QV sobre a imagem Monalisa .....	20
Tabela 4.5 Resultados obtidos após aplicação da QV sobre a imagem Lena.....	21
Tabela 4.6 Resultados obtidos após aplicação da QV sobre a imagem Mandrill.....	21
Tabela 4.7 Comparação entre valores de PSNR para as duas técnicas estudadas a uma mesma taxa de compressão .....	24

## Sumário

1	Introdução.....	1
1.1	Objetivos .....	1
1.2	Organização do Trabalho .....	1
2	Fundamentação Teórica.....	3
2.1	Representação de imagens digitais.....	3
2.2	Imagens digitais coloridas.....	5
2.3	Compressão de imagens.....	6
2.3.1	Transformada Discreta do Cosseno (DCT) .....	7
2.3.2	Quantização Vetorial (QV) .....	11
2.3.2.1	Formulação do problema da quantização vetorial.....	12
2.4	Avaliação das Imagens.....	13
2.4.1	Métodos Subjuntivos.....	13
2.4.2	<i>Peak Signal-to-Noise Ratio</i> (PSNR).....	14
2.5	Conclusão .....	14
3	Metodologia.....	16
3.1	Aplicando a DCT .....	16
3.2	Aplicando a Quantização Vetorial.....	17
4	Resultados.....	18
4.1	DCT .....	18
4.2	Quantização Vetorial.....	20
4.3	Análise comparativa entre os métodos utilizados.....	23
5	Conclusão e Perspectivas.....	25
6	Bibliografia.....	26

# 1 Introdução

Com o acentuado desenvolvimento tecnológico nos últimos anos, as imagens digitais tornaram-se cada vez mais difundidas. Seu uso está presente em diversas áreas, na medicina (diagnósticos por imagem), sistemas de satélite, segurança, entretenimento e várias outras aplicações, tendo em comum o fato de exigirem grandes quantidades de dados, tanto para armazenamento quanto para transmissão. Por exemplo, uma imagem colorida digital no padrão RGB e resolução de  $1024 \times 768$  pixels exige mais de 2 MB para ser representada [1].

A compressão de dados é de fundamental importância para todas essas aplicações. Ela visa otimizar a transmissão e armazenamento de dados com baixo custo computacional. O princípio básico do funcionamento dessas técnicas de compressão é identificar e remover redundâncias ou informações irrelevantes podendo ser uma compressão com perdas ou sem perdas dependendo da aplicação em questão.

Em uma compressão de imagem sem perdas a imagem é perfeitamente reconstituída após o processo de descompressão. Dessa forma não há perdas de informação, em contrapartida, atinge baixas taxas de compressão. São bastante utilizadas em imagens médicas em que a perda de informação pode conduzir um médico a um diagnóstico errôneo.

Na compressão com perdas a imagem recuperada não é perfeitamente igual à original, mas é possível atingir altas taxas de compressão. São utilizadas na grande maioria das aplicações nas quais a portabilidade da imagem é mais importante que sua qualidade visual, sem, no entanto deteriorá-la significativamente[2].

## 1.1 Objetivos

Este trabalho tem como objetivo principal o estudo do comportamento de duas das mais conhecidas técnicas de compressão de imagens: a Transformada Discreta do Cosseno (DCT, do inglês *Discrete Cosine Transform*) e a Quantização Vetorial (QV).

Para se alcançar este objetivo, primeiramente foi necessário designar objetivos mais específicos:

- Realizar uma pesquisa bibliográfica sobre representação de imagens digitais e as principais técnicas de compressão de imagens existentes.
- Familiarizar-se com as técnicas de compressão de imagens em ambiente computacional e implementar algoritmos para realizar a compressão de imagens conhecidas.

## 1.2 Organização do Trabalho



Além deste capítulo introdutório, este relatório é composto por mais quatro capítulos que apresentam os conteúdos a seguir.

No segundo capítulo é apresentada a fundamentação teórica que rege este estudo, começando pela representação digital das imagens, a teoria da compressão e uma descrição das duas técnicas de compressão estudadas, mostrando sua formulação matemática e aplicações utilizando-se de ilustrações autoexplicativas.

O terceiro capítulo descreve todo o desenvolvimento necessário para se atingir os objetivos introduzidos pela aplicação das técnicas de quantização vetorial e transformada discreta do cosseno para imagens coloridas.

Os resultados e discussões são apresentados no quarto capítulo. Foram utilizadas tabelas, gráficos e imagens que ilustram bem o comportamento das técnicas de compressão de acordo com a variação de seus parâmetros.

Para finalizar, o quinto capítulo apresenta as conclusões do trabalho, destacando sua contribuição para a formação do aluno e as perspectivas que a continuação desse estudo pode trazer.

## 2 Fundamentação Teórica

### 2.1 Representação de imagens digitais

Uma imagem digital monocromática é uma função  $f(x,y)$  em duas dimensões na qual os valores de  $x$  e  $y$  correspondem às coordenadas espaciais e o valor de  $f$ , ao brilho ou intensidade luminosa (tons de cinza)[3]. Pode-se dizer que ela consiste em uma matriz bidimensional de tamanho  $M \times N$  em que cada elemento (célula) porta um valor de  $f$ . Este elemento é chamado de *pixel* e porta valores inteiros que normalmente variam de 0 a 255 (Figura 2.1).

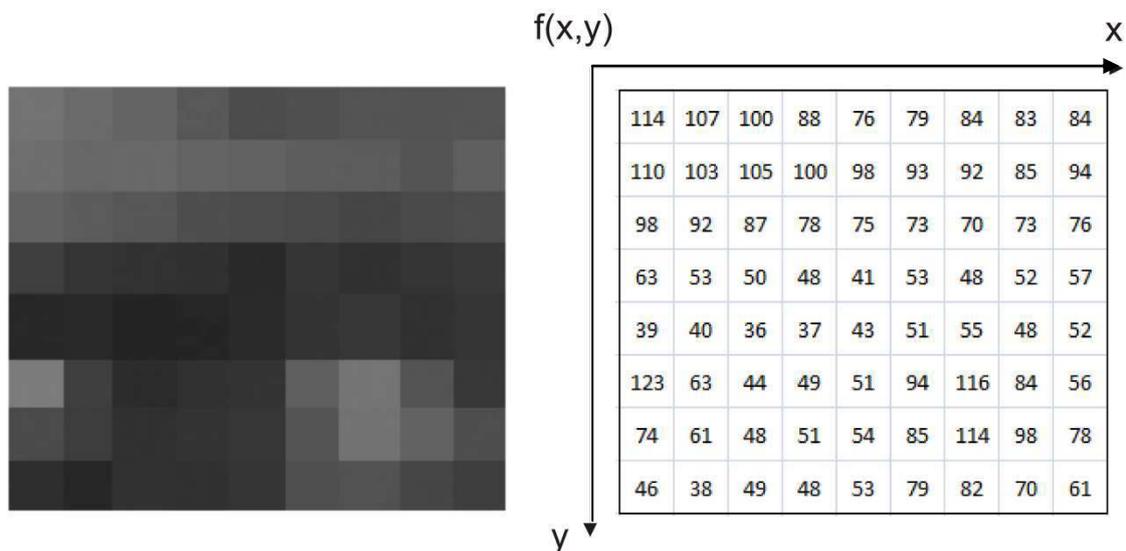


Figura 2.1 Imagem digitalizada com resolução espacial 8x9 e sua respectiva representação matricial com 256 níveis de cinza

Para que uma imagem seja propriamente digital é necessário passar por um processo de digitalização, que consiste em realizar uma amostragem e quantização da imagem analógica (Figura 2.2). A amostragem está intimamente ligada à resolução espacial da imagem, ou seja, quantos pixels são utilizados para representá-la. Já a quantização nos dá a ideia de profundidade. Ela define a quantidade de níveis de cinza utilizados para representar cada pixel. Quanto mais bits por pixel, mais níveis de cinza serão utilizados.

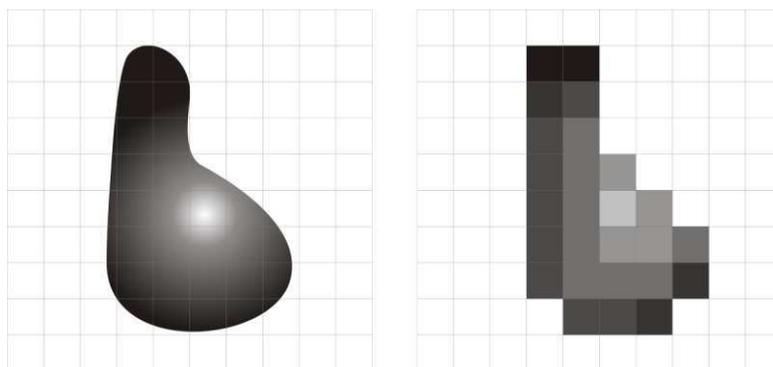


Figura 2.2 (a) Exemplo de imagem contínua (b) Resultado de uma amostragem e quantização

Para se ter uma ideia do comportamento desses parâmetros nas imagens digitais, apresentamos na Figura 2.3 a mesma imagem para três resoluções diferentes. Verifica-se o fenômeno do bloqueio (quadriculamento) da imagem, ou seja, há uma degradação na qualidade visual da imagem à medida que sua resolução é reduzida. Já para a quantização, à medida que se diminui o número de níveis de cinza, os detalhes da imagem tendem a aparecerem como formas homogêneas, uma vez que não se dispõe de muitas intensidades para reproduzir detalhes de sombreamento e iluminação, por exemplo. (Figura 2.4). A esse fenômeno dá-se o nome de falso contorno [3] devido ao fato de se assemelharem a curvas de níveis topográficas.



Figura 2.3 (a) Representação de uma mesma cena para as seguintes resoluções: (a) 280x280 pixels (b) 140x140 pixels (c) 70x70 pixels



Figura 2.4 (a) Representação de uma mesma cena a (a) 4 bits (16 tons); (b) 3 bits (8 tons) e (c) 1 bit (2 tons) respectivamente.

## 2.2 Imagens digitais coloridas

Visto que as cores visíveis pelo olho humano podem ser representada por uma combinação de três cores primárias: vermelho, verde e azul (Padrão RGB, Figura 2.5), a representação matemática mais comum de imagens coloridas é um conjunto de três matrizes similares às de tons de cinza em que cada matriz bidimensional porta pixels referentes a uma dessas três cores que misturadas compõem a imagem. Ou seja, se eram utilizados 8 bits por pixel para representar uma imagem em tons de cinza, são necessários 24 bits por pixel para representar uma imagem colorida, sendo 8 bits para cada cor primária. Uma curiosidade é que valores iguais de R, G e B correspondem à escala de cinza, que vai do preto ( $R = G = B = 0$ ) ao branco ( $R = G = B = 255$ ), representada pela diagonal do cubo da Figura 2.5b. Verifica-se também a formação das cores ciano, amarelo e magenta que compõe outro padrão de cores, o CMYK (do inglês *Cian, Yellow, Magenta, Black Key*) utilizado em impressoras, pigmentos e tintas. É considerado um padrão subtrativo, pois o que se vê é resultado de reflexão da luz. No padrão RGB, o que se vê é formado pela própria luz.

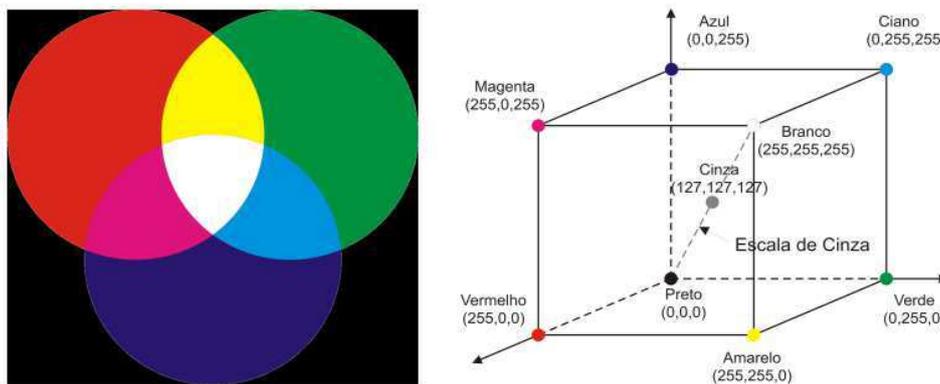


Figura 2.5 (a) Padrão de cores aditivo RGB. (b) Cubo esquemático para o padrão RGB

Na Figura 2.6 é ilustrada a imagem Tulipas com as três camadas de cor que a compõe. Elas são respectivamente o vermelho, o verde e o azul. Observa-se que as flores estão bem

escurcidas na camada azul, e mais claras nas camadas vermelha e verde, uma vez que o amarelo é representado por combinações de vermelho e verde. Em compensação, toda a carga de azul está sendo utilizada para representar o céu, que por ser azul claro, há uma boa contribuição das outras camadas. Para o detalhe em vermelho da pétala, as camadas verde e azul estão escuras, enquanto a contribuição da camada vermelha é bastante considerável.

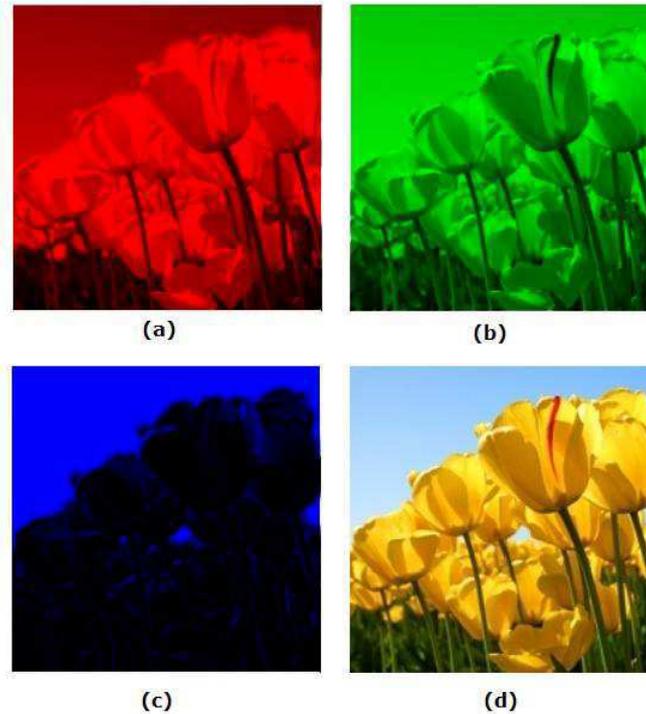


Figura 2.6 Contribuição de cada componente de cor na representação da imagem Tulipas, (a) Vermelho (R); (b) Verde (G); (c) Azul (B); (d) Imagem colorida

## 2.3 Compressão de imagens

A compressão de dados visa otimizar a representação digital de um sinal analógico, ou seja, utilizar a menor quantidade possível de bits mantendo a qualidade do sinal em patamares aceitáveis. Como já introduzido anteriormente, a compressão pode se dar *sem perdas* ou *com perdas* que seguem um mesmo princípio, a eliminação ou redução de redundâncias. Essas são basicamente três: redundância de *codificação*, redundância *interpixels* e redundância *psicovisual* [3].

Na redundância por codificação, pode-se citar o exemplo de um texto escrito na língua portuguesa em que a letra 'a' tende a aparecer com muito mais frequência que a letra y. No entanto utilizam a mesma quantidade de bits para serem representados, o que caracteriza a redundância de codificação. Dessa forma, atribui-se menos bits para caracteres ou até uma sequência que surja com mais frequência que outras. No âmbito das imagens,

tomando o exemplo de uma imagem em tons de cinza, pode-se atribuir uma quantidade de bits menor para valores de cinza mais prováveis nas imagens.

A redundância *interpixels* leva em consideração a correlação entre pixels, resultantes de relações geométricas ou estruturais entre objetos na imagem. É possível prever valores aproximados de pixels por meio dos valores de seus pixels vizinhos. Neste caso, a informação que este porta é relativamente pequena. Esta redundância geralmente é corrigida por transformadas nas quais é possível identificar pixels menos importantes e desconsiderá-los.

A redundância *psicovisual* reside no fato de que o olho humano não responde com igual intensidade a toda informação visual. A percepção humana de informações em uma imagem não envolve a análise quantitativa de cada pixel individualmente. Em geral, o observador procura por extremidades, contornos, regiões com textura e o cérebro correlaciona esses grupos para completar o processo de interpretação da imagem. A redução dessas redundâncias se baseia em reduzir as informações não essenciais no processo visual normal. Uma vez que há perdas de informação quantitativa, esse processo é normalmente referenciado como uma *quantização*. Um método bastante conhecido é o *improved gray-scale (IGS) quantization*, no qual é possível, por exemplo, representar uma imagem de 256 níveis de cinza com apenas 16. Ele reconhece a sensibilidade do olho humano às extremidades e as “quebra” adicionando para cada pixel um número pseudo-aleatório de acordo com pixels vizinhos, podendo representar uma imagem com menos bits e eliminando problemas de falso contorno.

### 2.3.1 Transformada Discreta do Cosseno (DCT)

São abordadas nesta seção as técnicas de compressão de imagens com a utilização das transformadas. As transformadas são ferramentas matemáticas capazes de levar o domínio de um sinal para outro permitindo a visualização de comportamentos deste que dificilmente seriam observados no domínio original. É de fundamental importância que as transformadas sejam inversíveis.

As transformadas são amplamente utilizadas no processamento de sinais. Algumas das suas finalidades são: a estimação de espectro, detecção de bordas, e remoção de ruídos. No processo de compressão a transformada mais utilizada é a DCT, que está presente nos padrões JPEG e MPEG2, por exemplo.

Antes de introduzir o conceito de DCT, é importante entender o princípio de funcionamento das transformadas no tratamento das imagens baseados na ótica de Fourier. Em resumo uma função arbitrária  $f(t)$  (satisfazendo algumas condições) pode ser decomposta em uma série de funções harmônicas de diferentes frequências e amplitudes complexas [4] (Figura 2.7).

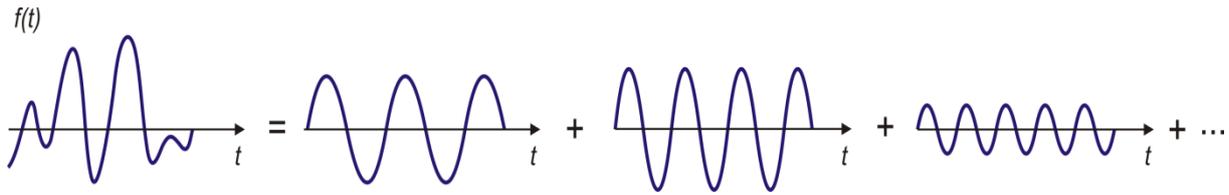


Figura 2.7 Uma função arbitrária  $f(t)$  analisada pela soma de funções harmônicas de diferentes frequências e amplitudes complexas.

De forma equivalente, uma função  $f(x,y)$  pode ser escrita como a superposição de funções harmônicas de  $x$  e  $y$  de amplitudes complexas e frequências espaciais (Figura 2.8). A frequência espacial é dada pelas variações espaciais de luminância. No SI sua unidade de medida é ciclos/m.

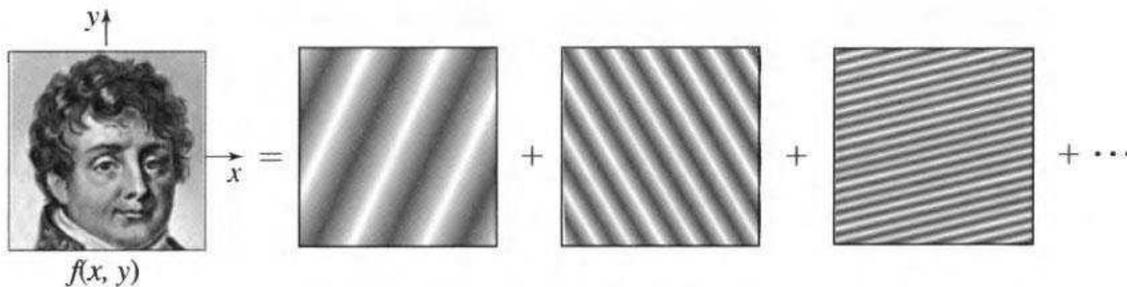


Figura 2.8 Imagem representada por uma soma de funções harmônicas de diferentes frequências e amplitudes complexas após aplicação da transformada de Fourier. As partes brancas representam picos positivos e as pretas, picos negativos. (Extraída de [4])

A DCT foi proposta em 1974 por Ahmed, Natarajan e Rao [5]. É amplamente utilizada em compressão de imagens, como por exemplo, os padrões JPEG e MPEG2. Similarmente à FFT, a DCT decompõe a imagem em uma série de formas de onda, em que cada uma possui uma frequência espacial própria. Ela explora bastante a redundância *interpixels*, uma vez que os pixels estão altamente correlacionados e suas informações individuais são pequenas, podendo ser prevista pelos pixels vizinhos. A utilização da DCT mapeia estes dados espaciais correlacionados em vários coeficientes reais não correlacionados.

Sua definição matemática pode ser dada por:

$$F(u, v) = \alpha(u)\alpha(v) \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} f(m, n) \cos \left[ \frac{\pi(2m+1)u}{2N} \right] \cos \left[ \frac{\pi(2n+1)v}{2N} \right], 0 \leq u, v \leq N-1 \quad (2.1)$$

Em que:

$$\alpha(u), \alpha(v) = \begin{cases} \frac{1}{\sqrt{N}} & u, v = 0 \\ \sqrt{2/N} & 1 \leq u, v \leq N-1 \end{cases}$$

Tendo com sua função inversa

$$f(m, n) = \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} \alpha(u)\alpha(v)F(u, v)\cos\left[\frac{\pi(2m+1)u}{2N}\right]\cos\left[\frac{\pi(2n+1)v}{2N}\right], 0 \leq m, n \leq N-1 \quad (2.2)$$

Os valores de  $F(u, v)$  são chamados de coeficientes da DCT de  $f(m, n)$  e podem ser observados como os pesos aplicados à cada função base (Figura 2.9), ou seja, cada coeficiente é multiplicado por sua função base correspondente e ao serem somados, contribuem para a formação da imagem final. O coeficiente (0,0) corresponde ao valor médio e é conhecido na literatura como coeficiente DC. Os coeficientes seguintes são conhecidos como coeficientes AC [6].

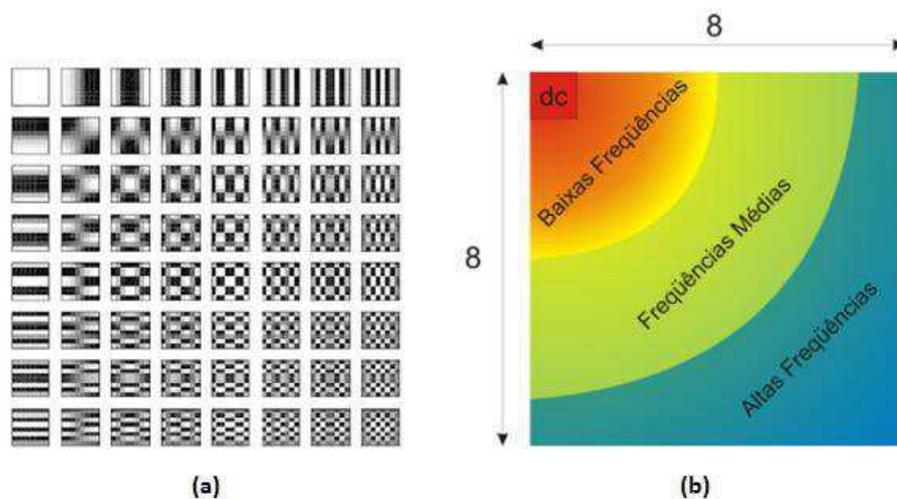


Figura 2.9 (a) As 64 funções base da DCT 8x8. As frequências horizontais crescem da esquerda para a direita enquanto as frequências verticais crescem de cima para baixo. Na posição (0,0) tem-se a função base de valor constante chamada de função base DC e seu coeficiente correspondente é conhecido como coeficiente DC. (b) Distribuição de frequência para o bloco 8x8.

A DCT particiona uma imagem inteira em blocos  $n \times n$  (8x8 é a mais utilizada) e aplica-se a Equação (2.1) separadamente para cada bloco. O resultado da aplicação da DCT para cada bloco é uma nova matriz 8x8 no domínio da frequência. A principal e desejada característica da DCT é que ela pode concentrar grande parte da energia nos coeficientes de frequências mais baixas. Dessa forma, pode-se eliminar a contribuição das frequências mais altas reduzindo assim a quantidade de bits necessária para armazenar a imagem.

A transformada que apresenta um desempenho ótimo para as propriedades de compactação de energia é a de Karhunen-Loève (KLT), mas a DCT é mais utilizada em compressão de imagens por apresentar um custo computacional bem mais baixo além de já existirem algoritmos rápidos desenvolvidos.

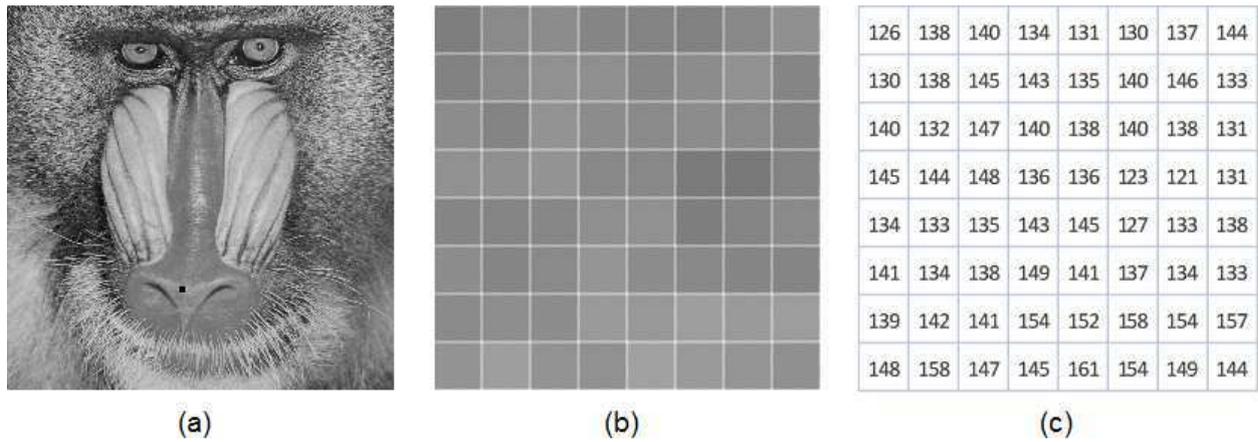


Figura 2.10 (a) Imagem Mandrill (b) Imagem em 8x8 pixels relativa ao bloco detalhado em preto na imagem em (a); (c) valores dos pixels relativos ao bloco

		N							
m		126	138	140	134	131	130	137	144
		130	138	145	143	135	140	146	133
		140	132	147	140	138	140	138	131
		145	144	148	136	136	123	121	131
		134	133	135	143	145	127	133	138
		141	134	138	149	141	137	134	133
		139	142	141	154	152	158	154	157
		148	158	147	145	161	154	149	144

Tabela 2.1 Valores dos pixels correspondentes ao bloco 8x8 detalhado na Figura 2.10a

		u							
v		1122,3	3,0	-12,6	-7,5	2,0	-0,2	-1,6	2,9
		-34,9	4,9	4,7	-14,0	-8,7	6,5	3,8	3,8
		25,0	-18,0	2,3	3,3	-12,8	-4,7	-4,3	-4,2
		-15,0	-10,7	0,6	-7,3	8,2	2,8	-3,6	-5,5
		-7,8	11,4	6,9	-5,5	4,0	-14,0	-4,2	6,2
		2,1	-0,2	6,6	-4,4	2,1	-2,8	6,2	-2,5
		-7,6	8,8	-0,6	3,9	1,2	1,1	3,4	2,6
		4,7	-16,9	-1,3	1,4	2,6	1,2	-0,6	0,2

Tabela 2.2 Coeficientes após aplicação da DCT sobre o bloco 8x8 correspondente à Tabela 2.1

Uma vez que somente aplicar a DCT não garante a compressão da imagem, é necessário fazer alguns ajustes para finalizar a compressão. Um primeiro método consiste em primeiramente em truncar os valores reais e trabalhar apenas com valores inteiros, realizar uma quantização dos valores dos coeficientes segundo algum critério. Na Figura 2.11 são apresentadas duas máscaras para quantização utilizadas no padrão de compressão JPEG. Cada valor do espectro é dividido pelo valor correspondente na máscara de quantização e o resultado então é arredondado para o inteiro mais próximo.

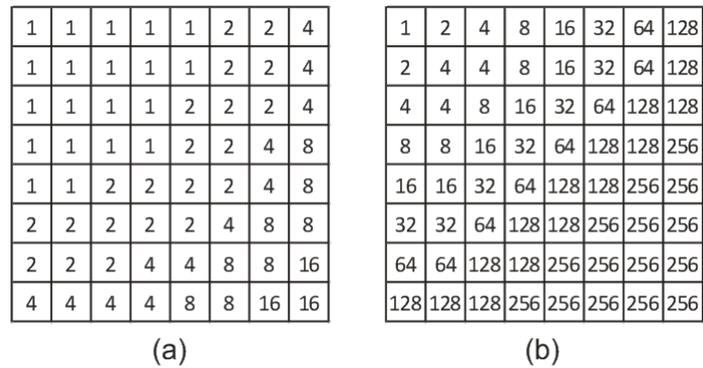


Figura 2.11 Algumas Máscaras de Quantização do padrão JPEG. Cada valor no espectro da DCT é dividido pelo valor correspondente na máscara de quantização e arredondado.

Verifica-se que os valores próximos ao canto inferior direito são maiores com o intuito de maximizar o número de coeficientes quantizados para zero. Esses valores correspondem às frequências mais altas que tendem a ser eliminadas uma vez que o sistema visual humano é pouco sensível às variações rápidas de imagem representada justamente por essas frequências.

Outro método de compressão consiste em descartar diretamente algumas frequências dentre os 64 valores de espectros. É sabido que quase todo o sinal está contido nas componentes de mais baixa frequência, o que significa que as frequências mais altas podem ser eliminadas, degradando assim apenas uma pequena quantidade do sinal.

### 2.3.2 Quantização Vetorial (QV)

A quantização vetorial vem se destacando como uma poderosa técnica de compressão de sinais [7]. Seu princípio básico é dividir parte do sinal em partes menores chamadas de vetores e associá-los a índices.

Em se tratando de imagens, a quantização vetorial particiona uma imagem em vetores bidimensionais (normalmente quadrados) e cada vetor é comparado a um conjunto de vetores padrão chamado *codebook* ou dicionário, armazenados no computador. O dicionário relaciona vários pequenos blocos de imagem a índices. Durante uma transmissão de dados, apenas os índices são enviados, sendo assim necessário que ambos codificador e decodificador utilizem o mesmo dicionário, similar a um *codec* necessário para se reproduzir vídeos de alta compressão.

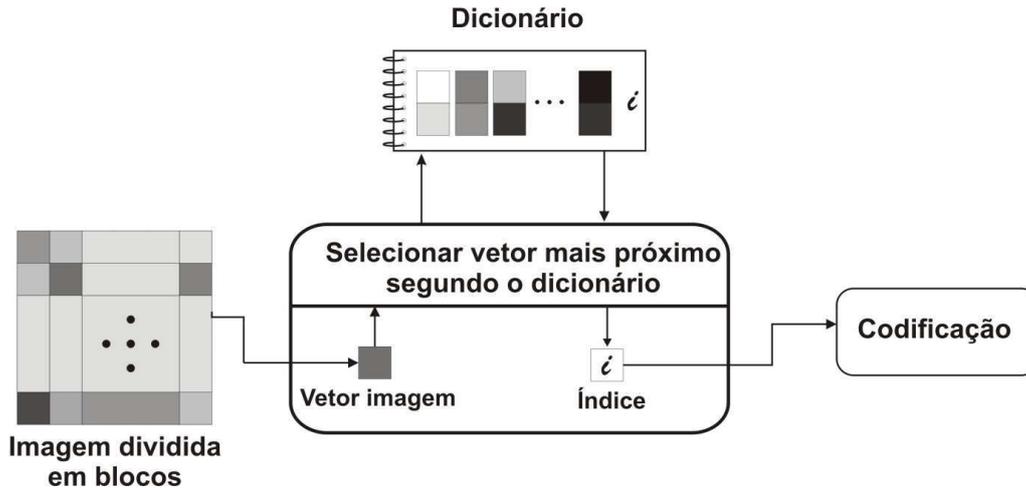


Figura 2.12 Representação da Quantização Vetorial. [Adaptado de [8]].

### 2.3.2.1 Formulação do problema da quantização vetorial

Considere  $x = [x_0 x_1 \dots x_{K-1}]^T$  um vetor de variáveis aleatórias de dimensão  $K$ . A quantização vetorial mapeia um vetor  $x$  em um outro vetor-código real  $y$  discreto em amplitude [9]. Desta forma, diz-se que  $x$  é quantizado por  $y$ . Normalmente o valor de  $y$  é escolhido dentre os valores de um conjunto finito  $Y = \{y_i, 0 \leq i \leq N - 1\}$ , chamado dicionário do quantizador vetorial, sendo  $y_i = [y_{i0} y_{i1} \dots y_{i(K-1)}]^T$ . O valor de  $N$  corresponde ao número de níveis e de vetores do dicionário e conseqüentemente o número de níveis do quantizador vetorial.

Durante o treinamento de dicionários o espaço  $K$ -dimensional de  $x$  se divide em  $N$  regiões ou células  $\{R_i, 0 \leq i \leq N - 1\}$  e a cada região  $R_i$  é atribuído um vetor  $y_i$ . Caso ele estiver contido na região  $R_i$ , será então representado por  $y_i$  como representado na Figura 2.13.

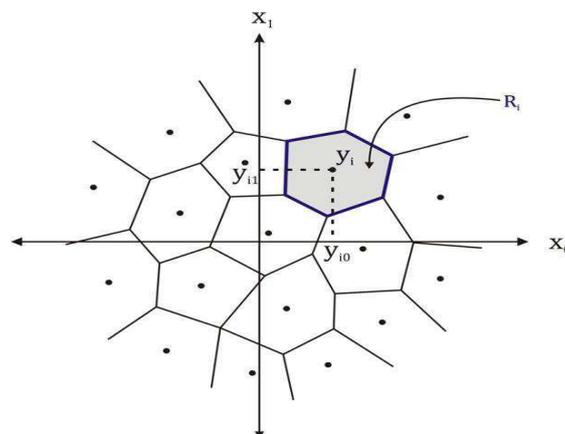


Figura 2.13 Partição do espaço bidimensional em 18 células ( $N = 18$ ). Todos os vetores de entrada na célula  $R_i$  serão quantizados como  $y_i$ .

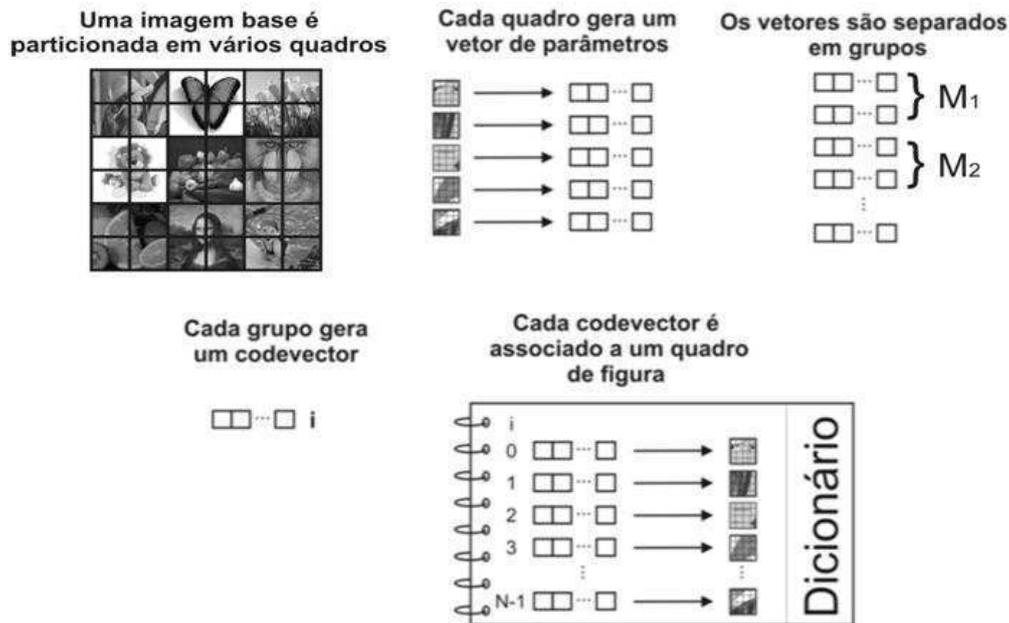


Figura 2.14 Etapas do processo de geração de um dicionário. Adaptado de [10].

Um método amplamente utilizado no projeto de dicionários é o Algoritmo de Linde-Buzo-Gray [11]. No escopo deste trabalho não será abordada a construção do algoritmo de treinamento dos dicionários, mas na Figura 2.14 é apresentado um resumo de como se obtém um dicionário.

Na quantização vetorial de imagens os vetores são geralmente formados pela divisão da imagem em blocos de  $K = K_1 \times K_2$  pixels [7]. Uma métrica muito importante para a quantização vetorial é a taxa de codificação em bits por pixel (bpp) dada por:

$$R = (\log_2 N)/K; \tag{2.3}$$

em que  $N$  é o número de vetores do dicionário (níveis) e  $K$  sua dimensão, ou seja, o número de pixels por bloco.

## 2.4 Avaliação das Imagens

Para avaliar a qualidade de uma imagem comprimida existem dois critérios: os subjetivos e os objetivos.

### 2.4.1 Métodos Subjetivos

Para as avaliações subjetivas, normalmente é feito uma enquete com um grupo de pessoas, interrogando-as sobre a qualidade de uma imagem comprimida em relação a sua imagem original. Este tipo de avaliação é conhecido como *Escore Médio de Opinião*, no qual ao final da enquete, é feito uma média das notas atribuídas por cada participante. Na Tabela

2.3 é apresentada uma escala de notas para avaliação de imagens comprimidas proposto pela "Television Allocations Study Organization".

Tabela 2.3 Notas para critério de avaliação subjetivo da "Television Allocations Study Organization"

Valor	Avaliação	Descrição
1	Excelente	Imagem de qualidade extremamente alta, tão boa quanto se poderia imaginar.
2	Boa	Imagem de alta qualidade, permitindo visualização agradável. A interferência não prejudica
3	Regular	Imagem de qualidade aceitável. A interferência não prejudica.
4	Limite	Imagem de qualidade ruim; você gostaria de poder melhorá-la. A interferência é um tanto prejudicial.
5	Ruim	Imagem muito ruim, mas você pode apreciá-la. Interferência prejudicial faz-se definitivamente presente.
6	Inútil	Imagem tão ruim que você não pode apreciá-la.

#### 2.4.2 Peak Signal-to-Noise Ratio (PSNR)

Como critério de avaliação objetivo, tem-se a Relação Sinal-Ruído de Pico (*Peak Signal-to-Noise Ratio* - PSNR). Matematicamente ela é definida como 10 vezes o logaritmo na base 10 da razão entre o quadrado do pico de amplitude do sinal de entrada e o erro médio quadrático (*Mean Square Error* - MSE). Como normalmente as imagens são representadas a 8 bits por pixel (tons de cinza ou cada camada de cor de uma imagem colorida), o valor de pico é 255. Assim a PSNR é dada por

$$PSNR = 10 \log_{10} \left( \frac{255^2}{MSE} \right). \quad (2.4)$$

O erro médio quadrático entre duas imagens  $F(i, j)$  e  $\hat{F}(i, j)$  (original e a comprimida respectivamente) de dimensões  $m \times n$  é dado por:

$$MSE = \frac{1}{n.m} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} [F(i, j) - \hat{F}(i, j)]^2. \quad (2.5)$$

## 2.5 Conclusão

Este capítulo abordou de forma sucinta a fundamentação teórica empregada no desenrolar do trabalho. Primeiramente introduziu-se a teoria da representação de imagens em tons de cinza e coloridas, bem como padrões de cores e noção de amostragem e quantização.

Em seguida iniciou-se a abordagem de duas das importantes técnicas de compressão de imagens, a DCT e a QV, que se baseiam na eliminação ou redução da redundância de informações contidas nas imagens.



Apresentou-se também uma breve teoria da Transformada Discreta do Cosseno e da Quantização Vetorial e algumas de suas aplicações. Por fim, foram introduzido os critérios de avaliação de imagens.

### 3 Metodologia

Uma vez apresentada a fundamentação teórica, agora é apresentada a metodologia empregada no desenvolvimento deste trabalho.

Foram utilizadas três diferentes imagens coloridas a saber: *Lena*, *Mandrill* e *Monalisa*. Todas com a mesma resolução espacial  $256 \times 256$  pixels, codificadas a 24 bits/pixel.

#### 3.1 Aplicando a DCT

Dados os objetivos apresentados na Seção 1.1, foi desejado verificar o comportamento da DCT bidimensional em imagens coloridas. Para tal fim, primeiramente foi necessário decompor a imagem em suas três camadas de cores: vermelha, azul e verde (RGB) e tratá-las individualmente.

Neste trabalho foi escolhida a técnica do descarte das frequências mais altas, considerando-se apenas alguns dos coeficientes. A dimensão dos blocos escolhida foi  $8 \times 8$  e os parâmetros escolhidos para análise foram:

- Componente DC + 3 AC mais baixos
- Componente DC + 9 AC mais baixos
- Componente DC + 15 AC mais baixos
- Componente DC + 53 AC mais baixos

Utilizou-se para tal as seguintes máscaras:

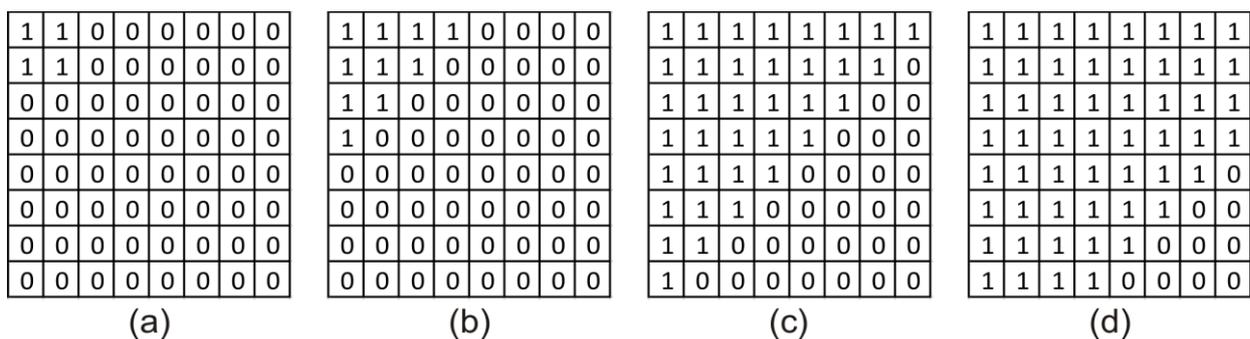


Figura 3.1 Máscaras correspondentes às 4 transformações realizadas: (a) 4 Coeficientes; (b) 10 Coeficientes; (c) 36 Coeficientes; (d) 56 Coeficientes.

Depois foi aplicada a DCT inversa para se reconstruir as imagens comprimidas. Todas as etapas da DCT foram implementadas usando a ferramenta *MATLAB*, que fornece uma ampla diversidade de funções para o tratamento de imagens digitais.

### 3.2 Aplicando a Quantização Vetorial

A primeira etapa corresponde à decomposição da imagem colorida em suas três camadas de cor e é idêntica àquela realizada na aplicação da DCT. A quantização vetorial também foi aplicada a cada camada de cor diferente individualmente e reagrupada para compor a imagem final comprimida.

Neste projeto utilizou-se uma quantização vetorial com valor de  $K = 4 \times 4 = 16$ , ou seja, a imagem foi particionada em 4096 blocos, cada um deles foi comparado a um bloco existente em um conjunto de diferentes blocos (dicionário) e substituído pelo bloco que mais se aproxima, pela regra do vizinho mais próximo, recebendo apenas o índice correspondente.

Os diferentes casos analisados foram:

- Dicionário de  $N = 32$  níveis
- Dicionário de  $N = 64$  níveis
- Dicionário de  $N = 128$  níveis
- Dicionário de  $N = 256$  níveis
- Dicionário de  $N = 512$  níveis

Cada dicionário foi construído utilizando o algoritmo *LBG* utilizando como imagem base um conjunto das seguintes imagens: *Airplane*, *Boats*, *Gull*, *Goldhill* como ilustrado na Figura 3.2.



Figura 3.2 Imagem base para treinamento de dicionários utilizando algoritmo LBG

Depois de aplicada a quantização vetorial para cada camada de cor, as três foram reagrupadas para formar a imagem colorida comprimida.

## 4 Resultados

Realizado o desenvolvimento, são apresentados agora os resultados para cada caso analisado. Para todos eles foi calculado o valor de *PSNR* e a taxa de compressão (*R*) e foram plotadas as curvas da *PSNR* em função de *R*.

### 4.1 DCT

Primeiramente, a taxa de compressão para a DCT foi calculada por

$$R = \frac{\text{número de coeficientes considerados}}{64 \text{ coeficientes totais}} \quad (4.1)$$

A partir dos algoritmos desenvolvidos foram obtidos os seguintes resultados para as imagens qualificadas utilizando-se critérios objetivos (*PSNR*):

Tabela 4.1 Resultados obtidos após aplicação da DCT sobre a imagem Monalisa

Imagem: Monalisa		
Quantidade de Coeficientes	Taxa de Compressão <i>R</i>	PSNR (dB)
4	16 : 1	33,69810
10	6,4 : 1	35,65150
36	1,78 : 1	43,12360
54	1,18 : 1	53,06060

Tabela 4.2 Resultados obtidos após aplicação da DCT sobre a imagem Lena

Imagem: Lena		
Quantidade de Coeficientes	Taxa de Compressão <i>R</i>	PSNR (dB)
4	16 : 1	32,72340
10	6,4 : 1	34,76710
36	1,78 : 1	39,68820
54	1,18 : 1	45,68730

Tabela 4.3 Resultados obtidos após aplicação da DCT sobre a imagem Mandrill

Imagem: Mandrill		
Quantidade de Coeficientes	Taxa de Compressão <i>R</i>	PSNR (dB)
4	16 : 1	30,12420
10	6,4 : 1	30,84370
36	1,78 : 1	33,42200
54	1,18 : 1	38,23140

Para uma melhor visualização e compreensão, os resultados obtidos foram plotados em ambiente MATLAB® e dispostos na Figura 4.1.

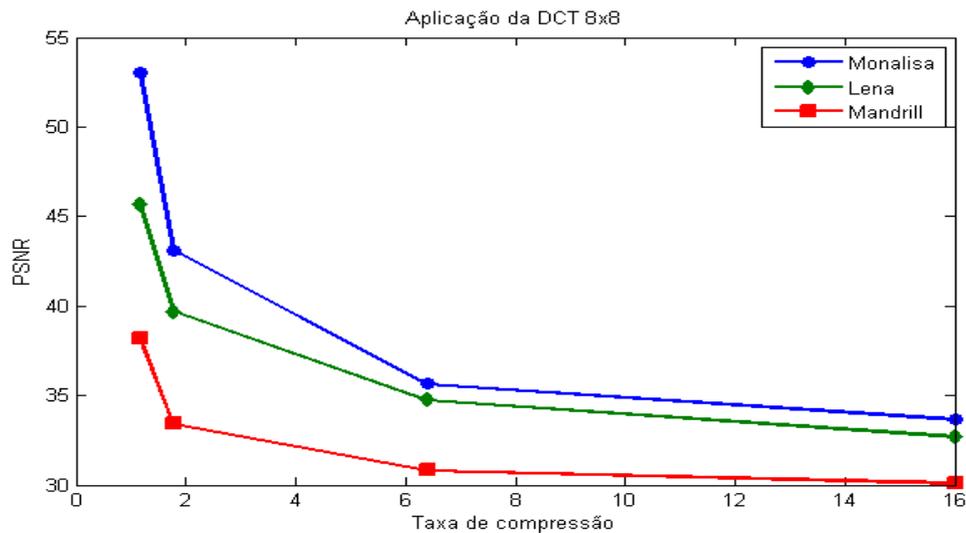


Figura 4.1 Curvas dos valores de PSNR em função da taxa de compressão resultantes da aplicação da DCT 8x8

A análise objetiva final demonstra que as imagens recuperadas mantiveram um aceitável índice de PSNR, igual ou superior a 30dB, o que mostra que não houve perdas significativas na qualidade da imagem.

Em seguida são apresentadas as imagens recuperadas após a aplicação dos algoritmos de compressão para os quatro diferentes casos estudados, permitindo se realizar para cada imagem uma análise subjetiva.

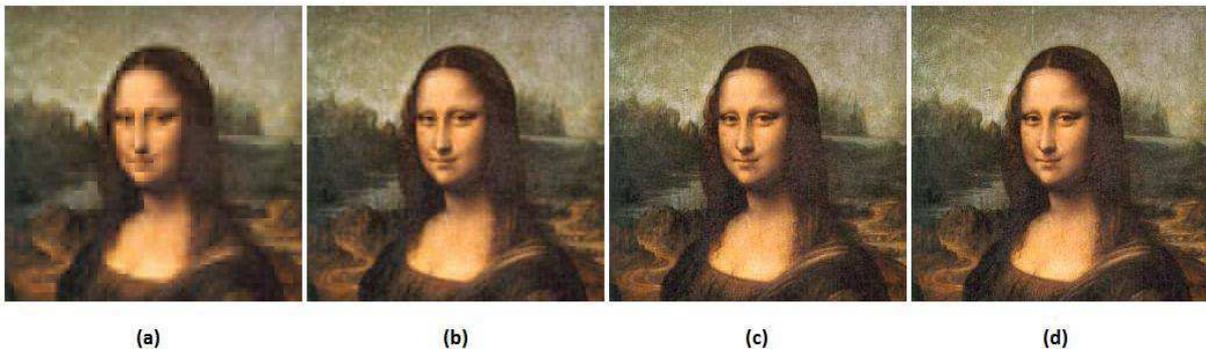


Figura 4.2 Imagem Monalisa para (a) 4 Coeficientes (b) 10 Coeficientes (c) 36 Coeficientes (d) 56 Coeficientes



Figura 4.3 Imagem Lena para (a) 4 Coeficientes (b) 10 Coeficientes (c) 36 Coeficientes (d) 56 Coeficientes

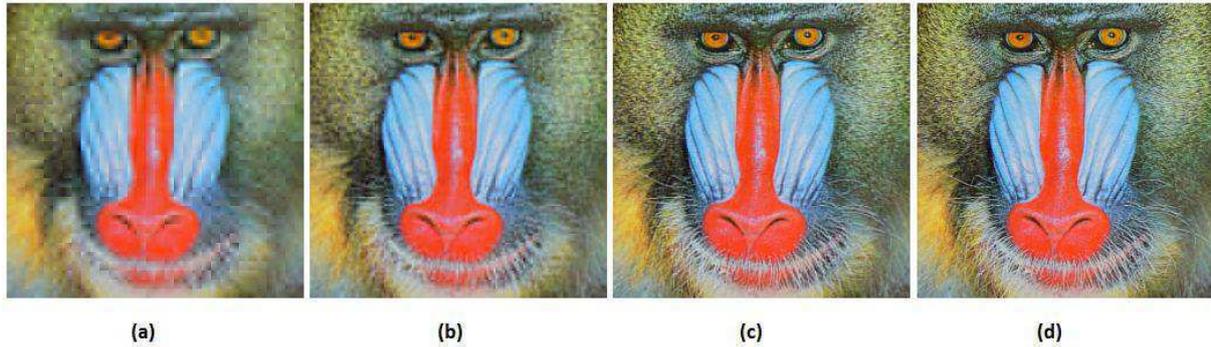


Figura 4.4 Imagem Mandrill para (a) 4 Coeficientes (b) 10 Coeficientes (c) 36 Coeficientes (d) 56 Coeficientes

Analisando-se cada imagem subjetivamente (Figuras Figura 4.2, Figura 4.3 e Figura 4.4), verifica-se a presença de "borramento" nas imagens recuperadas a 4 coeficientes, que vai desaparecendo a medida que se aumenta o número de coeficientes utilizados na recuperação da imagem. Utilizando-se apenas 10 coeficientes, já é possível observar uma imagem de boa qualidade para diversas aplicações mesmo ainda apresentando um ligeiro "borramento". Utilizando-se 36 coeficientes, observa-se uma imagem de excelente qualidade, sendo quase imperceptíveis quaisquer diferenças entre essas e as imagens recuperadas a 54 coeficientes. É importante salientar que essa análise é válida para a versão digital deste relatório uma vez que as impressoras utilizam o padrão subtrativo de cores *CYMK*, apresentam uma menor resolução e não representam tão fielmente as cores vistas em monitores.

## 4.2 Quantização Vetorial

Como já visto anteriormente, o cálculo da taxa de compressão para a quantização vetorial é dado pela Equação (2.3). São apresentados então a seguir os resultados obtidos aplicando-se o algoritmo de quantização vetorial para cada uma das três imagens estudadas.

Tabela 4.4 Resultados obtidos após aplicação da QV sobre a imagem Monalisa

Imagem: Monalisa		
Níveis do Dicionário	Taxa de Compressão $R$	PSNR (dB)
32	25,60 : 1	27,64301
64	21,33 : 1	28,58712
128	18,28 : 1	29,19290
256	16 : 1	29,70177
512	14,22 : 1	30,20064

Tabela 4.5 Resultados obtidos após aplicação da QV sobre a imagem Lena

Imagem: Lena		
Níveis do Dicionário	Taxa de Compressão $R$	PSNR (dB)
32	25,60 : 1	25,58775
64	21,33 : 1	26,49202
128	18,28 : 1	27,15660
256	16 : 1	27,66204
512	14,22 : 1	28,14684

Tabela 4.6 Resultados obtidos após aplicação da QV sobre a imagem Mandrill

Imagem: Mandrill		
Níveis do Dicionário	Taxa de Compressão $R$	PSNR (dB)
32	25,60 : 1	22,05304
64	21,33 : 1	22,53822
128	18,28 : 1	22,95561
256	16 : 1	23,31686
512	14,22 : 1	23,66656

Para uma melhor visualização e compreensão, os resultados obtidos foram plotados em ambiente MATLAB® e dispostos na Figura 4.5.

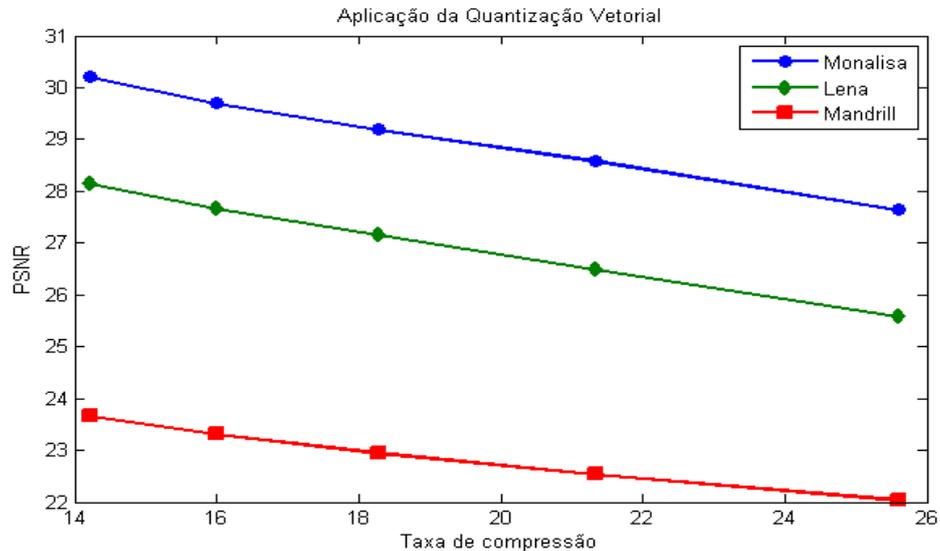


Figura 4.5 Curvas dos valores de PSNR em função da taxa de compressão resultantes da aplicação da Quantização Vetorial

Realizando-se uma análise objetiva, verifica-se que as imagens recuperadas apresentaram baixos índices de PSNR, o que representa perdas significativas na qualidade da imagem. Em compensação, atingiram elevadas taxas de compressão, o que pode ser muito útil em aplicações que demandem um menor tráfego na rede ou espaço para armazenamento sem a necessidade de uma qualidade visual tão apurada.

Para a realização de uma análise subjuntiva são apresentadas as imagens recuperadas após a aplicação dos algoritmos de quantização vetorial para os cinco diferentes casos analisados.

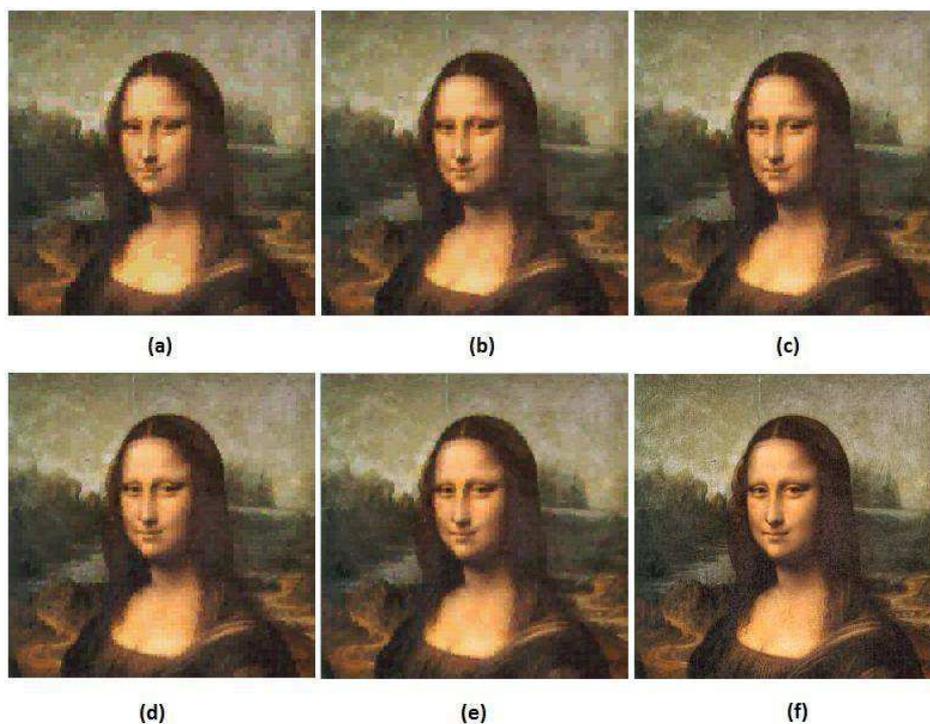


Figura 4.6 Imagem Monalisa reconstruída utilizando dicionários com as respectivas quantidades de níveis: (a) 32 Níveis (b) 64 Níveis (c) 128 Níveis (d) 256 Níveis (e) 512 Níveis; (f) Imagem original para comparação



Figura 4.7 Imagem Lena para reconstruída utilizando dicionários com as respectivas quantidades de níveis: (a) 32 Níveis (b) 64 Níveis (c) 128 Níveis (d) 256 Níveis (e) 512 Níveis; (f) Imagem original para comparação

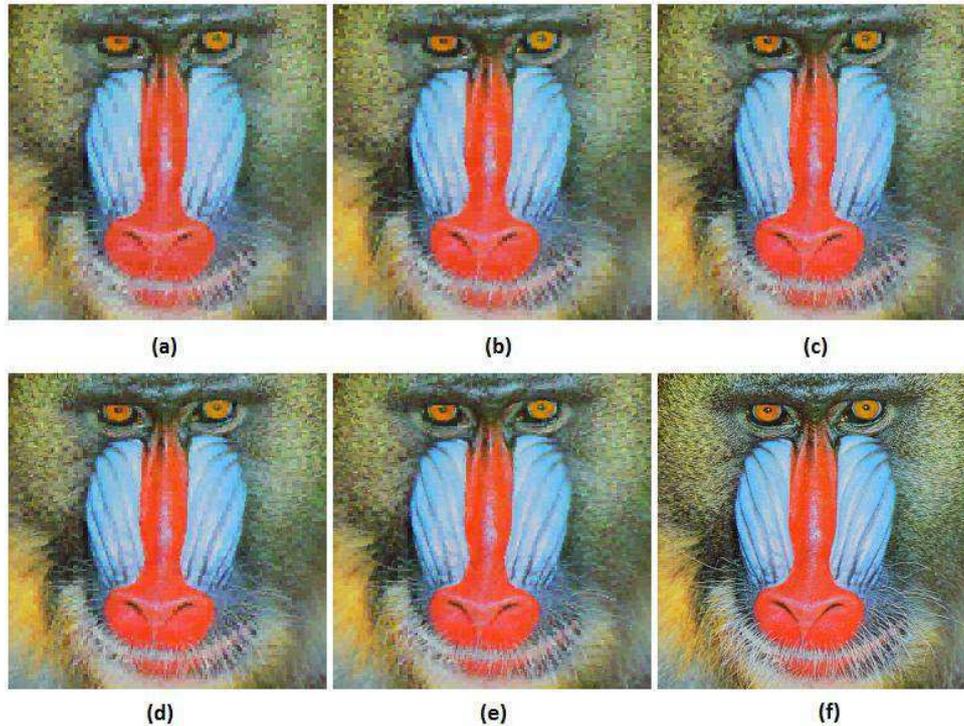


Figura 4.8 Imagem Mandrill para reconstruída utilizando dicionários com as respectivas quantidades de níveis: (a) 32 Níveis (b) 64 Níveis (c) 128 Níveis (d) 256 Níveis (e) 512 Níveis; (f) Imagem original para comparação

Após realizada uma análise subjetiva para as imagens recuperadas (Figuras Figura 4.6, Figura 4.7 e Figura 4.8), verifica-se uma forte presença de bloqueio (imagem quadriculada) nas imagens recuperadas que não apresentam melhoras tão significativas na sua qualidade à medida que se aumenta o número de níveis para os dicionários. Verifica-se mesmo no melhor caso (512 níveis) a imagem recuperada não apresenta muita fidelidade à imagem original, o que justifica os baixos índices de PSNR obtidos pela aplicação da Quantização vetorial (Figura 4.5) na qual apenas uma medida foi superior a 30dB.

### 4.3 Análise comparativa entre os métodos utilizados

Comparando-se subjetivamente as imagens reconstruídas, verifica-se para a DCT que as imagens apresentam boa qualidade visual a partir da utilização de 10 dentre os 64 coeficientes. O mesmo não é tão acentuado na Quantização vetorial, mas em compensação esta apresenta um maior poder de compressão em relação à DCT.

Objetivamente, comparando-se as duas técnicas, convém confrontar os valores de PSNR para uma mesma taxa de compressão (16 : 1) alcançada pela utilização de 4 coeficientes na DCT e a utilização de um dicionário de 256 níveis na quantização.

Pela Tabela 4.7 verifica-se que a DCT preserva mais a qualidade da imagem mesmo utilizando apenas 4 coeficientes de frequência, demonstrando mais uma vez sua capacidade de compactação de energia. Os valores de PSNR para a DCT foram bastante superiores aos obtidos na quantização vetorial.

Tabela 4.7 Comparação entre valores de PSNR para as duas técnicas estudadas a uma mesma taxa de compressão

Imagem	Valor de PSNR (dB)	
	DCT (4 Coeficientes)	QV (N = 256 Níveis)
Monalisa	33,69810	29,70177
Lena	32,72340	27,66204
Mandrill	30,1242	23,31686

## 5 Conclusão e Perspectivas

Este trabalho abordou um tema importante área do processamento de imagens: a compressão. Foram escolhidas duas das mais conhecidas técnicas para compressão de imagens com perdas: a Transformada Discreta do Cosseno e a Quantização Vetorial.

Um estudo sobre essas técnicas foi realizado e foram apresentadas suas propriedades, tipos, e comportamento sobre a influência da variação de seus parâmetros, com a quantidade de informação considerada, a dimensão dos blocos utilizados e dicionários.

Analisando cada imagem subjetivamente verifica-se uma melhor qualidade de imagem nos resultados obtidos pela aplicação da DCT. Em compensação a quantização vetorial apresentou as maiores taxas de compressão. Essas observações estão de acordo com os resultados obtidos pela análise subjetiva utilizando PSNR, onde todas as imagens recuperadas na DCT alcançaram índices de PSNR superiores a 30dB e para a quantização vetorial, apenas uma medida atingiu este patamar.

Como melhorias sugeridas para se aumentar a taxa de compressão para a DCT citam-se a realização de quantização e normalização dos coeficientes de frequência e posterior aplicação de técnicas de codificação.

A baixa qualidade das imagens na quantização vetorial deveu-se em parte a utilização de apenas 4 imagens de treinamento diferentes no projeto do dicionário, o que conferiu pouca diversidade de vetores para a reconstrução das imagens. Sugere-se então trabalhar com uma quantidade maior de padrões de imagens no projeto dos dicionários.

Como perspectivas para este trabalho propõem-se a utilização das duas técnicas em cascata, ou seja, a utilização conjunta das duas técnicas para conseguir resultados ainda melhores explorando-se as diferentes características das duas técnicas.

Por fim, a realização deste trabalho permitiu uma boa aquisição de conhecimentos técnicos e um enriquecimento na formação intelectual, profissional e pessoal.

## 6 Bibliografia

- [1] DIEGO DE MIRANDA GOMES, "Compressão Seletiva de Imagens Coloridas com Detecção Automática de Regiões de Interesse," UFRN, Natal, Dissertação de Mestrado 2006.
- [2] JAKELINE FERREIRA SILVA, "Sistema de Armazenamento de Imagens Comprimidas Através da Transformada Wavelet," UNESP, Ilha Solteira, Dissertação de Mestrado S586s, 2008.
- [3] R. C. GONZALES and R. E. WOODS, *Processamento de Imagens Digitais.*: Editora Edgard Blucher LTDA, 2000.
- [4] B. E. A. SALEH and M. C. TEICH, *Fundamentals of Photonics*, 2nd ed. New Jersey, USA: Wiley, 2007.
- [5] N. AHMED, T. NATARAJAN, and K.R. RAO, "Discrete Cosine Transform," *IEEE TRANSACTIONS ON COMPUTERS*, pp. 90-93, January 1974.
- [6] H. PEDRINI and W. R. SCHWARTZ, *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*, 1st ed.: PIONEIRA THOMSON, 2008.
- [7] WASLON TERLLIZZIE ARAÚJO LOPES, "Diversidade em Modulação Aplicada à Transmissão de Imagens em Canais com Desvanecimento," UFCG, Campina Grande, Tese de Doutorado 2003.
- [8] JOÃO PAULO IGNÁCIO FERREIRA RIBAS, "Um modelo de compressão de imagens digitais baseado em Quantização Vetorial e transformações afins," UFU, Uberlândia, Tese de Doutorado 2008.
- [9] JOHN MAKHOUL, SALIM ROUCOS, and HERBERT GISH, "Vector Quantization in Speech Coding," *PROCEEDINGS OF THE IEEE*, vol. 73, no. 11, pp. 1551-1588, 1985.
- [10] RICARDO PARANHOS VELLOSO VIOLATO, "Estudo de algoritmos de quantização vetorial aplicados a sinais de fala," Unicamp, Campinas, Dissertação de Mestrado 2010.
- [11] Y. LINDE, A. BUZO, and R. GRAY, "An algorithm for vector quantizer design," *IEEE Trans Comm.*, vol. 28, no. 1, pp. 84-95, January 1980.
- [12] PAMELA C. COSMAN, KAREN L. OEHLER, EVE A. RISKIN, and ROBERT M. GRAY, "Using Vector Quantization for Image Processing," *PROCEEDINGS OF THE IEEE*, vol. 81, no. 9, 1993.
- [13] CHENG HUANG and YOULIAN ZHU, "Fast Algorithm for Arbitrary Length Discrete Cosine

Transform," in *Fifth International Conference on Natural Computation*, 2009, pp. 390-393.

- [14] JAMES E. FOWLER, MATHEW R. CARBONARA, and STANLEY C. AHALT, "Image Coding Using Differential Vector Quantization," *IEEE TRANSACTIONS ON CIRCUITS AND SYSTEMS FOR VIDEO TECHNOLOGY*, vol. 3, no. 5, pp. 350-368, Outubro 1993.
- [15] T.K. GRÖNFORS and N.S. PÄIVINEN, "Comparison of vector quantization methods for medical fidelity preserving lossy Compression of EMG signals," in *International Conference on Computational Intelligence for Modelling, Control and Automation*, 2005.
- [16] JIANQIN ZHOU and PING CHEN, "Generalized discrete cosine transform," in *Pacific-Asia Conference on Circuits, Communications and System*, 2009, pp. 449-452.
- [17] LIU YING, ZHOU HUI, and YU WEN-FANG, "Image Vector Quantization Coding Based on Genetic Algorithm," in *International Conference on Robotics, Intelligent Systems and Signal Processing*, Changsha, China, 2003, pp. 773-777.
- [18] JONAS GOMES and LUIZ VELHO, *Computação Gráfica: Imagem*. Rio de Janeiro: IMA/SBM, 1994.

