

KRISTIAN CAPELINE

**ANÁLISE DE TINTAS DE CANETAS
UTILIZANDO SEGMENTAÇÃO POR COR**

Dissertação apresentada ao Programa de Pós-Graduação em Informática Aplicada da Pontifícia Universidade Católica do Paraná como requisito parcial para obtenção do título de Mestre em Informática Aplicada.

CURITIBA

2005

KRISTIAN CAPELINE

**ANÁLISE DE TINTAS DE CANETAS
UTILIZANDO SEGMENTAÇÃO POR COR**

Dissertação apresentada ao Programa de Pós-Graduação em Informática Aplicada da Pontifícia Universidade Católica do Paraná como requisito parcial para obtenção do título de Mestre em Informática Aplicada.

Área de Concentração: *Computação Forense e Biometria*

Orientador: Prof. Dr. Jacques Facon

Co-orientador: Prof. Dr. Edson José Rodrigues Justino

CURITIBA

2005

Capeline, Kristian

Análise de Tintas de Canetas Utilizando Segmentação por Cor. Curitiba, 2005.
132p.

Dissertação de Mestrado – Pontifícia Universidade Católica do Paraná.

Programa de Pós-Graduação em Informática Aplicada.

1. Análise pericial de documentos questionados. 2. Segmentação de imagens coloridas. 3. Algoritmo classificador K-Means. 4. Modelo de cores.

I. Pontifícia Universidade Católica do Paraná. Centro de Ciências Exatas e de Tecnologia. Programa de Pós-Graduação em Informática Aplicada.

Dedico este trabalho aos meus pais, por terem
proporcionado tudo o que tenho hoje.
Os dois maiores guerreiros que já conheci !

Agradecimentos

À minha esposa pelo apoio, pela motivação e, principalmente, pela paciência em todas as fases deste projeto.

Aos meus pais e ao meu irmão, aos quais tive muito pesar em me manter afastado, porém souberam respeitar este momento de aprendizado. Em especial à minha mãe, pelas revisões deste trabalho e pelo companheirismo nos momentos mais difíceis.

Ao professor orientador Dr. Jacques Facon pelas contribuições seguras nas horas certas. Ao professor co-orientador Dr. Edson Justino pela dedicação e colaboração por este trabalho, pela preocupação por meu bem estar, pelo incentivo e compreensão em momentos difíceis e ainda por ter se demonstrado um grande companheiro.

À minha sogra pelas tantas vezes que se preocupou com minha saúde e me lembrou que tenho limites.

Aos amigos Cláudio Carvilhe, Joel Larocca, Alexandre Denes e Fernanda Hembercker por tudo que me ensinaram e pelo apoio e incentivo para o ingresso neste trabalho.

À professora e grande amiga Me. Isabelle Moletta pela motivação irrestrita em todas as etapas deste trabalho. Ao professor e amigo Luciano Gavinho pela confiança em meu trabalho, pelo apoio e pela compreensão nos momentos difíceis.

À Pontifícia Universidade Católica do Paraná pelo apoio financeiro, em especial ao professor Dr. Edson Justino que não mediu esforços em busca de auxílios financeiros.

Aos meus tantos amigos que entenderam minha ausência durante este trabalho.

Aos senhores Barrett, Bruford, Buarque, Butler, Coverdale, Dio, Gilian, Gilmour, Glover, Howe, Hughes, I. Anderson, Iommi, J. Anderson, Kaye, Lord, Loussier, Osbourne, Paice, Pauer, Squire, Townshend, Wakeman, Ward, Waters, White e Wright que com seus magníficos trabalhos me acompanharam e ajudaram em todas as etapas deste estudo.

Sumário

Agradecimentos	v
Sumário	vi
Lista de Figuras	ix
Lista de Tabelas	xiv
Lista de Símbolos	xv
Lista de Abreviaturas	xvii
Resumo	xix
Abstract.....	xxi
1 Introdução	1
1.1. Desafio.....	4
1.2. Motivação	5
1.3. Proposta	6
1.4. Contribuição	6
1.5. Organização da Dissertação.....	7
2 Fundamentação Teórica	8
2.1. Documentoscopia pelo Tratado de Perícias Criminalísticas	8
2.1.1. Grafoscopia.....	9
2.1.2. Alterações documentais	10
2.1.3. Exames de tintas.....	11
2.1.4. Exame de instrumentos escreventes	12
2.2. Introdução a Cores	12
2.3. Padrão CIE.....	14
2.3.1. Valores Triestímulos XYZ - CIE 1931	14
2.3.2. Diagrama de Cromaticidade CIE	16
2.4. Equipamentos Especializados.....	21
2.4.1. VSC - <i>Video Spectral Comparison</i>	22
2.4.2. TLC - <i>Thin-Layer Chromatography</i>	25
2.5. Modelos de Cores.....	27
2.5.1. O Modelo de Cores RGB.....	28

2.5.2. O Modelo de Cores CMYK	29
2.5.3. O Modelo de Cores HSI	31
2.5.4. Os Modelos de Cores YUV e YIQ.....	33
2.5.5. Níveis de Cinza	34
2.6. Conversões entre Modelos de Cores	35
2.6.1. Conversão do Modelo RGB para o CMYK.....	35
2.6.2. Conversão do Modelo RGB para o HSI.....	36
2.6.3. Conversão do Modelo RGB para o YUV	38
2.6.4. Conversão do Modelo RGB para o YIQ	39
2.6.5. Conversão para Níveis de Cinza	40
2.7. Reconhecimento de Padrões	42
2.7.1. Extração de Características	43
2.7.2. Classificação	44
2.7.3. O Classificador K-Means	47
2.8. Segmentação de Imagens Coloridas.....	51
2.9. Comentários Finais	53
3 Estado da Arte em Segmentação de Imagens Coloridas.....	54
3.1. Segmentação de Imagens Coloridas.....	55
3.1.1. Segmentação baseada em Classificadores	55
3.1.2. Segmentação baseada em Detecção de Bordas.....	60
3.1.3. Segmentação baseada em Extração de Regiões	62
3.2. Resumo do Estado da Arte Relevante	65
3.3. Visão Crítica do Estado da Arte.....	66
3.4. Comentários Finais	68
4 Método Proposto	69
4.1. Protocolo da Base de Dados	70
4.2. Processo de Aquisição (E1).....	72
4.3. Pré-tratamento (E2).....	75
4.4. Extração de Fundo (E3).....	77
4.5. Protocolo de Escolha de Características.....	88
4.6. Extração de Características (E4)	95
4.7. Separação das Tintas (E5)	96
4.8. Comentários Finais	98
5 Experimentos e Resultados	99
5.1. Experimentos e Análise Quantitativa dos Resultados.....	99
5.2. Análise Visual dos Resultados de outros Métodos de Segmentação	108
5.3. Comentários Finais	113
6 Conclusão e Trabalhos Futuros.....	114
6.1. Conclusão	114
6.2. Trabalhos Futuros	116
7 Referências Bibliográficas	118

Apêndices

A Documento do Processo de Aquisição	128
A.1. Introdução	128
A.2. Equipamentos Utilizados	128
A.2.1. Câmera Digital	129
A.2.2. Lentes Adicionais	129
A.2.3. Iluminação de Incidência	129
A.2.4. Canetas.....	130
A.2.5. Papel	130
A.2.6. Equipamentos Adicionais	130
A.3. Características do Processo de Aquisição	131
A.3.1. Equipamento de Aquisição	131
A.3.2. Equipamento de Iluminação.....	131
A.3.3. Lentes Adicionais	132

Lista de Figuras

Figura 1.1: Imagens de um documento questionado com uma alteração imperceptível ao olho humano (adaptado de [Mel03]). (a) Imagem capturada sobre uma iluminação branca. (b) Imagem capturada sobre uma iluminação filtrada.	2
Figura 1.2: Seção do espectro de energia eletromagnética mostrando	3
Figura 2.1: Representação do comprimento de onda (adaptado de [Col04]).....	13
Figura 2.2: Funções das observações de combinação de cores CIE XYZ $\bar{x}(\lambda)$, $\bar{y}(\lambda)$ e $\bar{z}(\lambda)$ em nanômetros entre 380nm e 780nm em intervalos de 5nm (adaptado de [Wal04])	15
Figura 2.3: Diagramas padrão CIE. Esquerda: visão 3D do diagrama. Direita-acima: visão perpendicular do plano. Direita-baixo: projeção no plano (X,Y), diagrama de cromaticidade. (adaptado de [Com03]).....	16
Figura 2.4: Diagrama de Cromaticidade CIE (adaptado de [Wal04]).....	17
Figura 2.5: Energia relativa dos padrões CIE A e D65, respectivamente. (adaptado de [Har03]).....	18
Figura 2.6: Energia relativa da média da luz do dia e de uma lâmpada fuorescente. (adaptado de [Har03]).....	19
Figura 2.7: Cores do diagrama CIE que podem ser representadas no modelo de cores RGB. Planos (X,Y), (X,Z) e (Z,Y), respectivamente. (adaptado de [Zha05])	19
Figura 2.8: Diagrama de Cromaticidade CIE demonstrando uma coordenada C não representável diretamente no modelo de cores RGB (adaptado de [Wal04]).....	20
Figura 2.9: Valores RGB correspondentes aos comprimentos de onda visíveis de 380nm à 780nm (adaptado de [Wal04])	21
Figura 2.10: Sistema padrão de aquisição de imagem espectral	22
Figura 2.11: Fotos de alguns equipamentos especializados para análise de documentos questionados utilizando o método VSC. (a) DPS 3. (b) Omniprint 1000A. (c) VSC 2000/HR (adaptado de [Kap03], [Mel03] e [FF03], respectivamente).....	23
Figura 2.12: Resultado da aplicação do equipamento VSC-4 da <i>Foster & Freeman</i> [FF03] (adaptado de [Nor05]). (a) Registro médico questionado onde a seta indica a linha a ser analisada. (b) Área questionada no equipamento antes da aplicação de filtros IR. (c) Área questionada vista no comprimento de onda	

IR 795nm, onde nota-se a ausência de refletância sobre a linha questionada. (adaptado de [Nor05]).....	23
Figura 2.13: Tipos de iluminação: (a) Iluminação por Incidência. (b) Iluminação por Transferência.....	24
Figura 2.14: Ilustração real de resultados de um processo utilizando TLC (adaptado de [Mic04]).....	27
Figura 2.15: Representação tridimensional do modelo de cores RGB (adaptado de [Sob03]). (a) Representação das coordenadas. (b) Representação das cores.....	29
Figura 2.16: Mistura de Cores (adaptado de [Har03]). (a) Aditivas. (b) Subtrativas.....	30
Figura 2.17: Representação tridimensional do modelo de cores HSI. (a) Representação das coordenadas (adaptado de [Mai03]). (b) Representação das cores (adaptado de [Sob03]).....	32
Figura 2.18: Plano $U-V$, $Y=5$, representado com cores do modelo RGB (adaptado de [Den05]).....	34
Figura 2.19: Exemplo de tonalidades em níveis de cinza.....	34
Figura 2.20: Modelo genérico do método de reconhecimento de padrões (adaptado de [San04]).....	43
Figura 2.21: Exemplo de classificação de padrões pelo conceito de proximidade. (adaptado de [TG74]).....	46
Figura 3.1: Experimentos de Zhang e Wang (adaptado de [ZW00]). (a) Imagem original. (b) Imagem contendo apenas o componente I . (c) Imagem contendo apenas o componente H . (d) Resultado final considerando os componentes I e H	56
Figura 3.2: Experimentos de Chen, Pappas, Mojsilovic e Rogowitz (adaptado de [CPM+02]). (a) Imagem original. (b) Imagem da segmentação por cores utilizando ACA. (c) Imagem da segmentação por texturas utilizando <i>wavelet</i> . (d) Imagem original segmentada.	57
Figura 3.3: Experimentos de Lee, Wang e Zhang (adaptado de [LWZ03]). (a) Imagem original. (b) Resultado da segmentação utilizando o método EM básico. (c) Resultado da segmentação utilizando o método K-EM.....	58
Figura 3.4: Experimentos de Lambert e Grecu (adaptado de [LG03]). (a) Imagem Original. (b) Resultado da segmentação ($\alpha = 0.1$). (c) Resultado da segmentação ($\alpha = 0.05$).....	59
Figura 3.5: Experimentos de Kenney e Manjunath (adaptado de [SKM04]). (a) Imagem original. (b) Imagem dos valores da <i>edge function</i> . (c) Imagem resultante do processo de difusão. (d) Imagem resultado da segmentação.	60
Figura 3.6: Experimentos de Martínez-usó, Pla e García-sevilla (adaptado de [MPG04]). (a) Imagem Original. (b) Resultado da detecção de bordas. (c) Resultado da segmentação.	61
Figura 3.7: Experimentos de Ihlow e Seiffert (adaptado de [IS03]). (a) Imagem original de uma célula de cevada transformada geneticamente. (b) Resultado da	

detecção de bordas por Canny ($\sigma = 5$, <i>low threshold</i> 0.16, <i>high threshold</i> 0.4). (c) Resultado da detecção de bordas por Canny ($\sigma = 12$, <i>low threshold</i> 0.16, <i>high threshold</i> 0.4).	62
Figura 3.8: Topologia de ilhas hexagonais. (adaptado de [DPA00])	63
Figura 3.9: Experimentos de Dorkó, Paulus e Ahlrichs (adaptado de [DPA00]). (a) Imagem de Entrada. (b) Imagem resultante da segmentação por <i>split and merge</i> . (c) Imagem resultante da segmentação por CSC.	64
Figura 3.10: Experimentos de Deng, Manjunath e Shin (adaptado de [DMS99]). (a) Imagem original. (b) Resultado do processo de quantização, com 13 cores. (c) Resultado após segmentação com escala 3 em 9 regiões. (d) Resultado final depois da união das regiões em 27 regiões.	65
Figura 4.1: Diagrama do método proposto (Nível 1)	69
Figura 4.2: Imagem original sem tratamento. (a) Documento selecionado para o processo de escolha de características. (b) Documento para o experimento.	72
Figura 4.3: Diagrama do método proposto: Etapa E2 (Nível 2)	76
Figura 4.4: Imagem pré-tratada. (a) do conjunto de imagens para escolha de características. (b) do conjunto de imagens para o experimento.....	77
Figura 4.5: Experimentos para conversão em níveis de cinza. (a) Imagem original colorida. (b) Imagem convertida para níveis de cinza atribuindo zero para o componente <i>S</i> do modelo HSI. (c) Imagem convertida para níveis de cinza utilizando o componente <i>H</i> do modelo HSI. (d) Imagem convertida para níveis de cinza utilizando a luminância <i>Y</i> do modelo YUV ou YIQ. (e) Imagem convertida para níveis de cinza utilizando o componente <i>G</i> do modelo RGB.....	80
Figura 4.6: Experimentos para extração de fundo. (a) Imagem pré-tratada. (b) Resultado do limiarizador Otsu sobre o componente <i>Y</i> do modelo de cores YUV ou YIQ. (c) Resultado do limiarizador Otsu sobre o componente <i>H</i> do modelo de cores HSI. (d) Resultado do classificador K-Means sobre o componente <i>Y</i> do modelo de cores YUV ou YIQ. (e) Resultado do classificador K-Means sobre o componente <i>H</i> do modelo de cores HSI.	83
Figura 4.7: Diagrama do método proposto: Etapa E3 (Nível 2)	84
Figura 4.8: Exemplo de um eixo do espaço de características delimitado pelo menor e pelo maior valor de características no eixo.....	85
Figura 4.9: Exemplo de um eixo do espaço de características delimitado pelos valores iniciais dos centros $z_1(\mathbf{1})$ e $z_2(\mathbf{1})$	85
Figura 4.10: Imagens de prova. (a) Imagem resultante da etapa de extração de fundo. (b) Primeira imagem de prova. (c) Segunda imagem de prova.....	90
Figura 4.11: Imagem exemplo da primeira prova	94
Figura 4.12: Imagem da classificação do conteúdo original, comparada à primeira prova....	94
Figura 4.13: Imagem exemplo da segunda prova.....	95

Figura 4.14: Imagem da classificação da alteração, comparada à segunda prova	95
Figura 4.15: Imagens de exemplo do início e término do processo. (a) Imagem original sem tratamentos de um documento para o experimento. (b) Exemplo de resultado do método proposto. Imagem da classificação do conteúdo original do documento. (c) Exemplo de resultado do método proposto. Imagem da classificação do conteúdo alterado do documento.	97
Figura 5.1: Gráfico da função de densidade da probabilidade demonstrando a distribuição da média dos resultados (linha azul), a média (linha vermelha) e os limites do desvio padrão (linhas verdes).....	101
Figura 5.2: Ilustração do depósito de diferenças quantidades de tinta em diferentes regiões da escrita. (a) Imagem sem fundo com diferenças de quantidades de tinta em seus traçados. (b) Imagem com seu histograma equalizado (Componente H do modelo HSI), onde a região com coloração verde representa a maior incidência de tinta.....	103
Figura 5.3: Descontinuidade de pixels em uma mesma classe. (a) Imagem da base de dados. (b) Imagem segmentado demonstrando regiões de uma classe que não apresentam continuidade.	105
Figura 5.4: Superposição de tintas. (a) Imagem pré-tratada demonstrando 2 regiões onde existe superposição de tintas. (b) Imagem de prova 1 demonstrando o tratamento para superposição de tintas. (c) Imagem de prova 2 demonstrando o tratamento para superposição de tintas.....	106
Figura 5.5: Exemplo 1 da menor média dentre os resultados: (a) Resultado do processo de pré-tratamento; (b) Resultado do processo de extração do fundo; (c) Imagem da prova do conteúdo original; (d) Imagem da prova do conteúdo alterado; (e) Resultado do processo de separação de tintas representando o conteúdo original; (f) Resultado do processo de separação de tintas representando o conteúdo alterado	107
Figura 5.6: Exemplo 2 da maior média dentre os resultados: (a) Resultado do processo de pré-tratamento; (b) Resultado do processo de extração do fundo; (c) Imagem da prova do conteúdo original; (d) Imagem da prova do conteúdo alterado; (e) Resultado do processo de separação de tintas representando o conteúdo original; (f) Resultado do processo de separação de tintas representando o conteúdo alterado	108
Figura 5.7: Resultados Imagem 1: (a) Resultado do processo de extração do fundo para ser utilizado por outros métodos. (b) Resultado do método JSEG [DMS99]. (c) Resultado do método VIS [SKM04]. Parâmetros: usar apenas cores, escala 10 de segmentação mínima e <i>balanced</i> . (d) Resultado da primeira região segmentada do método proposto. (e) Resultado da segunda região segmentada do método proposto.	111
Figura 5.8: Resultados Imagem 1: (a) Resultado do processo de extração do fundo para ser utilizado por outros métodos. (b) Resultado do método JSEG [DMS99]. (c) Resultado do método VIS [SKM04]. Parâmetros: usar apenas cores, escala 3 de segmentação mínima e <i>undersegment</i> . (d) Resultado da primeira	

região segmentada do método proposto. (e) Resultado da segunda região segmentada do método proposto. 112

Figura 5.9: Resultados do método VIS [SKM04]. (a) Parâmetros: usar apenas cores, escala 1 de segmentação mínima e *oversegment*. (b) Parâmetros: usar apenas cores, escala 5 de segmentação mínima e *undersegment*. 113

Lista de Tabelas

Tabela 3.1: Resumo do estado da arte relevante para a dissertação.....	65
Tabela 4.1: Estudo sobre formatos de arquivos da câmara digital.....	73
Tabela 4.2: Resultados de 10 execuções do classificador K-Means com inicialização aleatória de centros sobre uma imagem selecionada da base de dados.....	86
Tabela 4.3: Resultados da aplicação dos métodos de inicialização dos centros do classificador K-Means sobre as imagens selecionadas da base de dados.....	87
Tabela 4.4: Resultado do melhor conjunto de características para cada imagem da base de escolha de características.....	91
Tabela 4.5: Resultado da aplicação do melhor conjunto de características para cada imagem em todas as imagens da base de escolha de características.....	92
Tabela 4.6: Percentual médio dos resultados da aplicação do melhor conjunto de características para cada imagem em todas as imagens da base de escolha de características.....	92
Tabela 4.7: Resultados do exemplo do processo de escolha de características.....	95
Tabela 5.1: Resultados finais quantificados do método proposto.....	100
Tabela A.1: Descrição de lentes adicionais utilizadas.....	129
Tabela A.2: Descrição das canetas utilizadas.....	130

Lista de Símbolos

λ	Comprimento de onda.
$\bar{x}(\lambda)$	Valor triestímulo X do modelo de cores CIE XYZ com incidência de uma fonte de luz com comprimento de onda λ
$\bar{y}(\lambda)$	Valor triestímulo Y do modelo de cores CIE XYZ com incidência de uma fonte de luz com comprimento de onda λ
$\bar{z}(\lambda)$	Valor triestímulo Z do modelo de cores CIE XYZ com incidência de uma fonte de luz com comprimento de onda λ
$\bar{r}(\lambda)$	Valor do componente R do modelo de cores RGB com incidência de uma fonte de luz com comprimento de onda λ
$\bar{g}(\lambda)$	Valor do componente G do modelo de cores RGB com incidência de uma fonte de luz com comprimento de onda λ
$\bar{b}(\lambda)$	Valor do componente B do modelo de cores RGB com incidência de uma fonte de luz com comprimento de onda λ
$P(\lambda)$	Espectro de refletância no comprimento de onda λ .
ω	Agrupamento ou classe
K	Quantidade de classes para o algoritmo K-Means
k	Identificador da iteração corrente no algoritmo K-Means
$z_i(k)$	Centro da classe i na k -ésima iteração do algoritmo K-Means

$S_i(k)$	Conjunto de pontos da classe i na k -ésima iteração do algoritmo K-Means
d_{ij}	Distância entre i e j
x_{\bullet}	Amostra para classificação
N_i	Quantidade de elementos no conjunto de pontos da classe i do algoritmo K-Means
ε	Valor mínimo de movimentação dos centros do algoritmo K-Means
x	Valor normalizado do componente X do modelo de cores CIE XYZ, elemento do espaço de observações, elemento no espaço de características
y	Valor normalizado do componente Y do modelo de cores CIE XYZ, elemento do espaço de características
z	Valor normalizado do componente Z do modelo de cores CIE XYZ
m	Quantidade de dimensões do espaço de observações
p	Identificação de um padrão
q	Quantidade de dimensões do espaço de características, identificação de um padrão
r	Valor normalizado do componente R do modelo de cores RGB, quantidade de dimensões do espaço de decisões
g	Valor normalizado do componente G do modelo de cores RGB
b	Valor normalizado do componente B do modelo de cores RGB
α	Parâmetro de calibração da função de decisão de união de classes

Lista de Abreviaturas

ACA	<i>Adaptive Clustering Algorithm</i>
BPP	<i>Bits Per Pixel</i>
CCD	<i>Charge-Coupled Device</i>
CIE	<i>Commission Internationale de l'Eclairage</i>
CMOS	<i>Complementary Metal-Oxide-Semiconductor</i>
CMYK	<i>Cyan, Magenta, Yellow e Black</i>
CSC	<i>Color Structure Code</i>
DWT	<i>Discrete Wavelet Transform</i>
EM	<i>Algoritmo Expectation-Maximization</i>
FBI	<i>Federal Bureau of Investigation</i>
FCM	<i>Fuzzy C-Mean</i>
GMM	<i>Gaussian Mixture Model</i>
HQ	<i>Hight Quality</i>
HSI	<i>Hue, Saturation e Intensity</i>
HSx	<i>Hue, Saturation e x representa uma letra que determina o método de obtenção do brilho da imagem</i>
Interpol	<i>The International Criminal Police Organization</i>
IR	<i>Infrared</i>
ISO	<i>Do Grego isos, significa "igual". Nome dado para a Organização Internacional de Normalizações.</i>
JFIF	<i>Joint Photographic Experts Group - File Interchange Format</i>
JPG	<i>Joint Photographic Experts Group</i>
KFA	<i>Kernel Feature Analisys</i>

L*a*b*	CIELAB. <i>L</i> representa a luminância, <i>a</i> representa informações entre as cores vermelho e verde, <i>b</i> representa informações entre as cores verde e azul
mm	<i>Milímetros</i>
MRF	<i>Markov Random Fields</i>
nm	Nanômetros
NTSC	<i>National Television System(s) Committee</i>
PAL	<i>Phase-Alternating Line, Phase Alternation by Line</i> ou <i>Phase Alternation Line</i>
PCA	<i>Principal Component Analysis</i>
QT	<i>Quadtree</i>
RBF	<i>Radial Basis Function</i>
RGB	<i>Red, Green e Blue</i>
SHQ	<i>Super Hight Quality</i>
SIS	<i>Simple Image Statistic</i>
SLR	<i>Single Lens Reflex</i>
SMPTTE	<i>Society of Motion Picture and Television Engineers</i>
SNN	<i>Symmetric Nearest Neighbor</i>
SQ	<i>Small Quality</i>
TIFF	<i>Tagged Image File Format</i>
TLC	<i>Thin-Layer Chromatography</i>
VIS	<i>Variational Image Segmentation</i>
VSC	<i>Video Spectral Comparison</i> ou <i>Video Spectral Comparator</i>
YIQ	<i>Y</i> representa a luminância, <i>I</i> representa <i>Intermodulation</i> e <i>Q</i> representa <i>Quadrature</i>
YUV	<i>Y</i> representa a luminância, <i>U</i> e <i>V</i> representam a crominancia (matiz)

Resumo

A documentoscopia é uma área da ciência forense que se preocupa com a determinação da autenticidade de documentos questionados. Caso este documento seja manuscrito, a determinação da autenticidade é realizada pela grafoscopia, uma sub-área da documentoscopia. A abordagem proposta nesta dissertação baseia-se nos conceitos da grafoscopia para realizar a segmentação de imagens provenientes de documentos questionados, a fim de separar regiões com diferentes pigmentos de corante azul de canetas esferográficas. Atualmente, este processo é realizado através do uso de equipamentos óticos especializados, seguido de análises computacionais. O método proposto por este estudo utiliza equipamentos de baixo custo e que apresentam limitações quanto às informações que são digitalizadas das imagens, representadas pelo modelo de cores RGB. A base de dados é formada por imagens de documentos criados em laboratório por um único autor, a fim de simular possíveis alterações documentais. Foram utilizados 10 tipos de canetas, que possuem um caráter de uso popular, para a criação das alterações simuladas. As combinações em pares destas canetas geraram 45 imagens digitalizadas para análise, divididas em: imagens para o protocolo de escolha de características e imagens para experimentos. O método proposto divide-se nas seguintes etapas: etapa de aquisição (digitalização dos documentos questionados através do uso de uma câmera digital e de fontes luminosas com lâmpadas halógenas), pré-tratamento (conversão de formato, rotação e recorte da imagem original), extração de fundo (separação das regiões de tinta e de fundo através do uso do classificador K-Means, sobre a intensidade do nível de cinza do padrão NTSC/PAL) e finalmente o processo de separação das tintas (separação das duas tintas da imagem através do uso do classificador K-Means, sobre as características definidas no protocolo da escolha de características). Para validar o experimento 40 imagens da base de dados são utilizadas, sendo que os resultados apresentam as médias de 61,89% de acertos e 38,11% de erros. Conclui-se que os resultados obtidos não são suficientes para que o método proposto seja efetivamente utilizado em perícias, mas

indicam que o caminho seguido é promissor e abrem possibilidades de continuidade das pesquisas para o aperfeiçoamento do mesmo.

Palavras-Chave: 1. Análise pericial de documentos questionados. 2. Segmentação de imagens coloridas. 3. Algoritmo classificador K-Means. 4. Modelo de cores.

Abstract

The Questioned Document Examination (QDE) is a field of the Forensic Science correlated to questioned document authentication. In the manuscript document cases, the authentication is done by Graphometry, a QDE field. The proposed approach is based on the concepts of Graphometry to carry through the image segmentation proceeding from questioned documents, in order to separate regions with different ballpoint pen dye inks. Currently, this process is done through specialized optic equipments, followed computational analyses. The method considered for this study uses low cost equipments, with limited images information, represented by the RGB color space. The database is composed by document images created in laboratory, in order to simulate document adulterations. A set of 10 blue ball pens were used. The proposed method is divided in acquisition procedure, preprocessing, background extraction and inks separation. To validate the experiment, 40 images of the database are used, and the results present the averages of 61,89% of rightness and 38.11% of errors.

Keywords: 1. Document questioned expert's approach. 2. Color image segmentation. 3. K-Means algorithm. 4. Color models.

Capítulo 1

1 Introdução

Na ciência forense, a documentoscopia é definida como uma área da criminalística que se preocupa com o estudo da autenticidade dos documentos e com a definição da autoria destes [Men03]. Considerando um documento como qualquer meio físico de representação de informações, como por exemplo, vídeos, gravações sonoras, documentos escritos, entre outros. Dentre as diversas sub-divisões da documentoscopia, a grafoscopia preocupa-se com a definição da autenticidade de um documento questionado manuscrito. Considerando a autenticidade de documentos manuscritos, a grafoscopia define o processo de escrita como um gesto gráfico psicossomático que contém um número mínimo de elementos que possibilitam sua individualização [Men03]. Desta forma, processos grafotécnicos podem ser criados para determinar a autenticidade de documentos questionados e, em certos casos, identificar o autor da escrita. Outra sub-divisão da documentoscopia trata de alterações documentais, ou seja, toda modificação estrutural, seja através da supressão, do acréscimo ou da substituição de parte ou do todo dos dizeres de um determinado documento [Men03].

Tanto a grafoscopia quanto a análise de alterações documentais entre outros, possuem conceitos considerados como base para processos automáticos ou semi-automáticos para a análise digital de um documento questionado. Atualmente, a definição da autenticidade desses documentos implica, muitas vezes, na utilização de equipamentos óticos de precisão de custo elevado. A análise digital de documentos forenses através de processos computacionais é uma sub-área da ciência forense associada à documentoscopia. A adoção de processos computacionais, simplificando o processo usado atualmente, provoca uma redução nos custos do processo.

Dentre as diversas atividades associadas à ciência forense existentes, concentram-se aqui os estudos referentes à alterações de documentos por acréscimo realizadas por emendas, através de inserção de componentes manuscritos com o uso de canetas esferográficas. Existem diversos estudos com o objetivo de aumentar a confiabilidade e simplificar os processos de análise dessas alterações documentais, como por exemplo: na área física espectral [Kap03], [Mel03] e [FF03]; e na área físico-química cromatográfica [All98], [Nor05] e [TO98].

Um componente manuscrito inserido em um documento a fim de alterá-lo pode ser imperceptível ao olho humano, desta forma, torna-se necessário o uso de métodos ou equipamentos apropriados para sua análise. Assim a alteração pode ser salientada em relação ao restante do documento, conforme ilustrado na Figura 1.1(a) e na Figura 1.1(b).

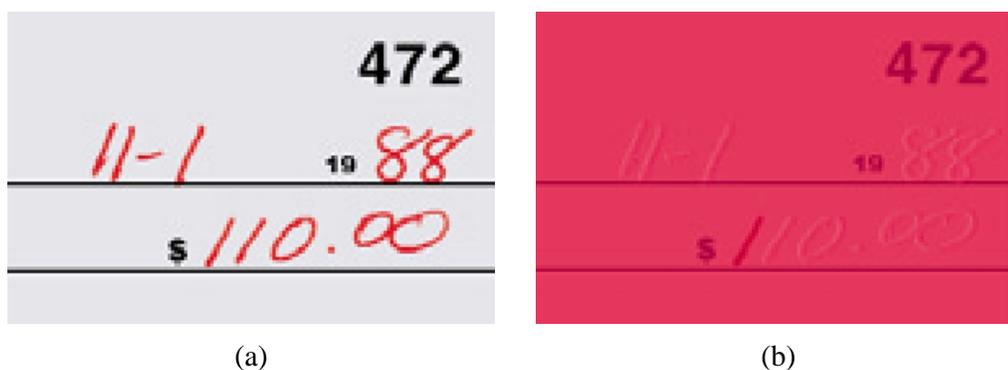


Figura 1.1: Imagens de um documento questionado com uma alteração imperceptível ao olho humano (adaptado de [Mel03]). (a) Imagem capturada sobre uma iluminação branca. (b) Imagem capturada sobre uma iluminação filtrada.

Quando a luz incide sobre uma superfície pode ocorrer um processo de reflexão e/ou de refração da luz. Esta luz é quantificada através de uma refletância espectral. O gráfico de refletância espectral representa a quantidade de energia luminosa refletida ou refratada de uma superfície em determinadas condições de iluminação, de utilização de filtros e de equipamentos de captação de dados, como câmeras por exemplo. Esta energia luminosa é tratada como ondas eletromagnéticas que incidem ou atravessam o material analisado [GW00].

As ondas eletromagnéticas existem em uma grande faixa de frequências, conhecida como espectro de energia eletromagnética. Este espectro é dividido em sub-regiões espectrais (Figura 1.2) com base na interação das ondas eletromagnéticas com o meio. O estudo da análise forense de documentos considera 3 dessas sub-regiões, este trabalho considera as sub-

regiões definidas por Gonzalez [GW00]. A primeira é a sub-região da luz infra-vermelho ($\approx 780\text{nm}$ à $\approx 1500\text{nm}$), que apresenta uma faixa de comprimento de onda superior à faixa de luz visível. Outra sub-região importante trata-se do ultra-violeta ($\approx 250\text{nm}$ à $\approx 380\text{nm}$), esta representa uma faixa de comprimento de onda inferior à faixa da luz visível. E finalmente a terceira, a sub-região de luz visível ($\approx 380\text{nm}$ à $\approx 780\text{nm}$), que se encontra entre as duas sub-regiões vistas anteriormente. Essas três sub-regiões apresentam propriedades importantes que propiciam a identificação de alterações em documentos [Kap03], [Mel03] e [FF03].

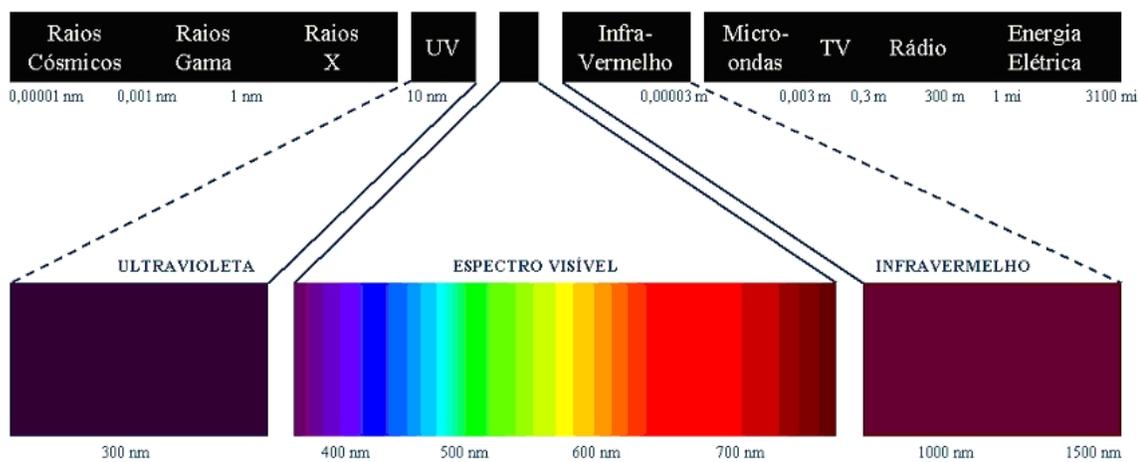


Figura 1.2: Seção do espectro de energia eletromagnética mostrando a escala de comprimentos de onda (adaptado de [GW00])

Este trabalho concentra-se no espectro visível de cores tratado computacionalmente. A representação da intensidade da cor de um *pixel*, tanto nos monitores de computador quanto nos processos algorítmicos internos do mesmo, deve respeitar padrões de representação de cores, chamados de modelos de cores. Dentre os diversos modelos de cores existentes, este trabalho considera basicamente os modelos RGB, CMYK, HSI, YIQ e YUV, conforme detalhado na Seção 2.5. Estes modelos de cores baseiam-se no modelo de cores padrão CIE XYZ (ou CIE 1931), este padrão define comprimentos de onda para as cores visíveis através de observações humanas e foi criado pela CIE (*Comissão Internationale de l'Eclairage*) em 1931.

Na área de Visão Computacional, o conceito de reconhecimento de padrões pode ser definido como a categorização de dados de entrada em classes identificáveis [San04]. O reconhecimento de padrões consiste basicamente na extração de características relevantes da

imagem e na classificação dessas informações. O processo de classificação é o objetivo principal do reconhecimento de padrões e pode ser utilizado como uma parte do processo de segmentação da imagem.

A segmentação de uma imagem consiste na partição desta em regiões, de acordo com alguns critérios, a fim de localizar algum objeto (ou região) de interesse [DMS99]. O processo de segmentação é considerado como crítico e de considerável complexidade no processamento de imagens digitais [DMS99], [LWZ03]. Desta forma, o processo de identificação de alterações proposto, deverá ser complementado com a análise visual dos resultados por peritos em grafoscopia.

Considerando a abrangência dos tipos de alterações e dos materiais que podem ser utilizados para alterações de documentos, este trabalho concentra-se no estudo de documentos próprios criados em laboratório. Diversos parâmetros foram considerados e documentados para que a base de dados pudesse ser reproduzida em outras aplicações e dentre os mais relevantes, encontram-se informações sobre o tipo de papel, as canetas utilizadas, as luzes, os equipamentos de aquisição, as lentes e as medidas de distância utilizadas para todos os equipamentos (Apêndice A).

1.1. Desafio

A abordagem proposta tem como principal desafio apresentar resultados compatíveis com métodos que utilizam equipamentos especializados, através do uso de equipamentos de baixo custo. Processos físico-químicos cromatográficos e alguns processos físicos espectrais necessitam de diversos equipamentos que fornecem informações não disponíveis no método proposto por este trabalho, por este utilizar um conjunto de equipamentos mais reduzido e simplificado. Por exemplo, métodos físicos espectrais especializados utilizam informações filtradas em faixas de frequências fornecidas pela incidência e/ou transferência de espectros luminosos. Os processos físico-químicos cromatográficos fornecem informações de reações químicas de solventes em contato com a amostra. O método proposto, por sua vez, utiliza equipamentos que não são capazes de distinguir faixas muito próximas de frequência do espectro de cores.

Considerando que existem ilimitadas formas de realizar uma alteração em um documento, a criação da base de dados deve ser suficientemente representativa para abranger

uma grande quantidade dessas possibilidades. Em um caso extremo, porém não raro, um mesmo indivíduo pode alterar dois documentos nas mesmas circunstâncias porém utilizando diferentes forças: vertical e/ou lateral (Seção 2.1). Desta forma, a caneta esferográfica pode depositar diferentes quantidades de massa corante sobre a superfície, dificultando o processo de análise do pigmento do corante.

O processo de classificação para o reconhecimento de padrões necessita que sejam fornecidas características relevantes da imagem para uma classificação satisfatória. A seleção das melhores características para distinção de diversas classes pode ser um processo difícil, muitas vezes exigindo diversas análises através de processos computacionais [San04].

O processo de segmentação é considerado como crítico no processamento de imagens digitais [DMS99], [LWZ03]. Normalmente este processo necessita da definição de diversos parâmetros *a priori*, o que determina que o método de segmentação é fortemente dependente dos mesmos. O método proposto deve ser automático e não deve depender de parâmetros para sua execução.

1.2. Motivação

Atualmente, mesmo com a existência de equipamentos especializados, grande parte das análises de documentos questionados é realizada através de processos manuais. Estes processos normalmente fornecem resultados qualitativos e muitas vezes questionáveis. A criação de um método computacional para definição quantitativa dos resultados, representa um aumento na confiabilidade deste processo. Desta forma, os resultados podem ser mais exatos e menos contestáveis, além de provavelmente serem gerados em um intervalo menor de tempo.

Os métodos que utilizam análises químicas muitas vezes são considerados inviáveis, pois são de natureza destrutiva. Esses métodos apresentam a necessidade de extração física da tintura do material para análise, o que modifica a estrutura desse. Assim, um método computacional elimina essa necessidade e permite com que o documento seja re-analisado, caso o resultado seja contestado.

Comparando com métodos que utilizam equipamentos especializados, a definição de um método com menor custo poderia ajudar muitas entidades em seus processos forenses.

Contudo, a principal motivação deste trabalho é a possibilidade de aplicação do método proposto por estas entidades, a fim de melhorar a qualidade dos serviços prestados pelas mesmas.

1.3. Proposta

A proposta deste trabalho é apresentar um método computacional de segmentação de imagens coloridas para discriminar regiões com diferentes pigmentações do corante azul de canetas esferográficas. Dentro deste contexto as seguintes metas são propostas:

- Criar uma base de documentos em laboratório que simule possíveis alterações documentais.
- Utilizar no processo de aquisição das imagens um conjunto suficiente de equipamentos de baixo custo.
- Criar um processo de extração do fundo das imagens, a fim de permitir a análise apenas de regiões onde há incidência de tintas.
- Criar um método de segmentação não-parametrizado que considera apenas informações de cores dos *pixels*, não considerando informações espaciais e/ou de vizinhança destes.

1.4. Contribuição

As contribuições deste trabalho de pesquisa são relacionadas como segue:

- Um método alternativo para discriminação de pigmentos do corante de canetas esferográficas com caráter não-destrutivo e com um menor custo comparado com alguns métodos utilizados atualmente;
- Um método de extração de fundo de imagens de fragmentos de documentos questionados, independente dos pigmentos do corante das tintas utilizadas;
- O uso apenas de valores das cores dos *pixels*, dispostos em modelos de cores, para segmentação de diferentes pigmentações do corante azul de tintas de canetas esferográficas, sem considerar informações de textura e/ou informações espaciais;

- Um método de segmentação específico para alterações documentais em documentos questionados, porém sem a necessidade de definição de parâmetros.

1.5. Organização da Dissertação

Esta dissertação está organizada em sete capítulos. O primeiro capítulo descreve uma introdução à análise forense de documentos, bem como suas características para processos de análise digital. O segundo capítulo contém a fundamentação teórica que foi utilizada para o desenvolvimento do método proposto. O terceiro capítulo apresenta um resumo do estado da arte de processos computacionais de segmentação de imagens coloridas. O quarto capítulo apresenta detalhadamente todas as etapas do método proposto. Os experimentos e resultados são descritos no quinto capítulo. No sexto capítulo são apresentadas as conclusões e propostas para trabalhos futuros. E finalmente, no sétimo capítulo são apresentadas as referências bibliográficas utilizadas para o desenvolvimento deste trabalho.

Capítulo 2

2 Fundamentação Teórica

Como a aplicação do método proposto destina-se exclusivamente às aplicações forenses, um estudo sobre documentoscopia pelo Tratado de Perícias Criminalísticas é descrito neste capítulo (Seção 2.1).

Este capítulo apresenta os estudos sobre métodos e técnicas utilizados para o desenvolvimento do método proposto. Nenhum dos estudos que compõem esta base teórica tratam especificamente da solução do tema proposto, porém algumas de suas características foram utilizadas neste trabalho. Sobre o tratamento computacional de cores, este capítulo apresenta uma introdução e um estudo sobre o padrão internacional CIE para representação de cores (Seções 2.2 e 2.3), alguns modelos de cores (Seção 2.5) e seus métodos de conversão (Seção 2.6). Em relação aos métodos utilizados para classificação de imagens considerando suas cores, é descrito resumidamente os conceitos da área de reconhecimento de padrões (Seção 2.7), salientando o algoritmo de classificação K-Means. Por fim, são apresentadas a fundamentação do processo de segmentação de imagens coloridas (Seção 2.8) e os equipamentos e processos especializados (Seção 2.4), que atualmente realizam a segmentação de documentos questionados através de processos físicos ou físico-químicos.

2.1. Documentoscopia pelo Tratado de Perícias Criminalísticas

Conforme Mendes [Men03], o Tratado de Perícias Criminalísticas é utilizado por diversos juízes e desembargadores que fundamentam decisões e sentenças em seus conteúdos. Adicionalmente, o tratado também serve como fonte de consulta para diversos advogados, promotores, delegados de polícia e peritos, no exercício de suas atividades.

Todo o estudo sobre o Tratado de Perícias Criminalísticas apresentado neste trabalho baseia-se nas análises de Mendes [Men03], que define a documentoscopia como uma área da criminalística que se preocupa com o estudo da autenticidade dos documentos e com a definição da autoria destes. Considerando um documento como qualquer meio físico de representação de informações, como por exemplo, vídeos, gravações sonoras, documentos escritos, entre outros.

A documentoscopia é dividida em diversas sub-áreas, como segue:

- Grafoscopia;
- Mecanografia;
- Alterações de documentos;
- Exame de moedas metálicas;
- Exame de selos;
- Exame de papel-moeda;
- Exame de papéis;
- Exame de tintas;
- Exame de instrumentos escreventes, e;
- Outros exames relacionados.

Os estudos aqui descritos baseiam-se em definições das seguintes sub-áreas: grafoscopia, alterações de documentos e exame de tintas e de instrumentos escreventes.

2.1.1. Grafoscopia

A grafoscopia é uma sub-área da documentoscopia preocupada com o estudo da escrita e de seus elementos, a fim de determinar a autenticidade e, caso necessário, determinar o autor. Isto diferencia a grafoscopia de outras disciplinas, como por exemplo, a grafologia, que estuda a personalidade do homem através do gesto gráfico.

Os peritos em grafoscopia classificam os documentos manuscritos, em relação à autenticidade, em autênticos ou adulterados [Jus00]. A autenticidade indica que o manuscrito

contido no documento em questão, não sofreu qualquer modificação, tais como: retirada de texto ou a inclusão de novos conteúdos. A adulteração indica que o documento sofreu algum tipo de manipulação, tais como a inclusão de novos conteúdos, por exemplo.

Existem diversos fatores que interferem na definição da autenticidade de um documento através de uma análise grafoscópica. Dentre estes, para os estudos descritos neste documento, consideram-se as características da formação do traço. Um traço é formado por duas forças:

- **Vertical:** Força que pressiona o instrumento escrevente, e;
- **Lateral:** Força do movimento no suporte.

Sendo que a reunião de dois ou mais traços formam um traçado.

Com a análise dos traços pode-se notar diferenças na pressão exercida pelos escritores sobre o instrumento de escrita. E, analisando os traçados, pode-se notar que um mesmo traçado pode apresentar diferenças de pressão em sua composição.

As diferenças de pressão resultam em diferentes sulcagens no papel, ou seja, baixo relevo deixado pelo instrumento escrevente no papel. Para Justino [Jus99], esta pressão exercida pelos escritores pode ser resumida em duas características: a escrita tensa e a escrita frouxa. Estas informações podem auxiliar nos processos de autenticação de autores [Jus99], porém na análise para determinar adulterações por acréscimo (Seção 2.1.2), tem-se como pressuposto que o indivíduo adulterador realiza uma pressão em sua escrita muito próxima à exercida pelo indivíduo que escreveu o conteúdo original.

Quanto à espessura do traço, com o uso da mesma caneta esferográfica não existem diferenciações entre traços grossos e finos. Diferenças estas que podem ser notadas apenas com o uso de diferentes canetas esferográficas, ou seja, com canetas que possuam diferenças no diâmetro de suas esferas.

2.1.2. Alterações documentais

Mendes [Men03] define uma alteração documental como “toda modificação estrutural, seja através da supressão, do acréscimo ou da substituição de parte do texto de um

determinado documento”. As diversas formas de alterar um documento podem ser classificadas em dois grandes grupos, como segue:

- **Alterações por supressão:** Caracterizam-se pela realização de rasuras, raspagens, amputações e/ou lavagens químicas.
- **Alterações por acréscimo:** Caracterizam-se pela realização de retoques, emendas, acréscimos e/ou trancamentos.

As alterações por supressão são as que retiram ou escondem alguma parte de um documento, porém essas alterações não fazem parte desse estudo.

As alterações por acréscimo são caracterizadas pela inserção de novos elementos no documento original. Este estudo considera as alterações por acréscimo realizadas por emendas. As alterações com emendas consistem na inclusão de um traço, ou traços, em um algarismo do texto, a fim de alterar o significado deste.

2.1.3. Exames de tintas

Existem estudos sobre a história e evolução das tintas de escrever, desde registros de uso do carvão, passando por seivas, frutos, carbono, até as tintas atuais de secagem rápida [Men03]. Contudo, este trabalho apenas considera as tintas de secagem rápida utilizadas por um conjunto de canetas esferográficas.

Mendes [Men03] define o exame das tintas de escrever da seguinte forma: “O exame das tintas de escrever, seja para determinar a sua composição, seja para saber a data de seu lançamento, sempre constituiu problema de difícil solução, até mesmo, impossível na maioria dos casos”. Mendes enuncia diversos métodos propostos para resolução do problema, porém todos os métodos possuem algum fator que os torna impraticável e/ou inoperante. O único método com resultados considerados satisfatórios por Mendes é a espectrografia, porém este é desaconselhável pois implica na retirada de amostras do documento.

As análises dos corantes de instrumentos escreventes normalmente são realizadas sobre dois fatores: (1) o tipo de componente utilizado para dissolver o corante; (2) a pigmentação do corante. Existem basicamente 3 tipos de componentes químicos utilizados para dissolver o corante: gel, água e solvente. Dependendo da cor e do componente químico, diferentes processos químicos podem ser aplicados para discriminar tintas.

2.1.4. Exame de instrumentos escreventes

Como no exame de tintas, existem diversos estudos sobre a história e evolução dos instrumentos escreventes, desde as hastes metálicas para talhar pedras, passando por estiletos de madeiras, lascas de pedras cortantes, varetas de bambu, penas de animais, penas metálicas com farpas flexíveis, canetas-tinteiro até as canetas esferográficas [Men03]. Porém, este trabalho apenas considera as canetas esferográficas como instrumentos escreventes para análise.

A principal característica das canetas esferográficas é que dá o nome a mesma, é possuir uma esfera na sua extremidade escrevente. Esta esfera, através da rotação sobre seu próprio eixo, é embebida de uma massa corante que fica alojada em um recipiente contido no corpo da caneta. As massas corantes mais comuns apresentam matiz azul, vermelha ou preta. Neste trabalho serão consideradas as canetas de matiz azul.

Considerando as canetas esferográficas para diferenciar tonalidades de canetas de mesma cor é necessário a aplicação de um processo de análise da massa corante das canetas. Conforme Mendes [Men03], não existem processos hábeis para diferenciação significativa da massa corante das esferográficas de mesma cor e tonalidade. Contudo, exames foram realizados pelo autor utilizando colorimetria computadorizada e um espectrofotômetro, com resultados satisfatórios diferenciando diversas canetas existentes no mercado.

Existem diversos equipamentos de colorimetria computadorizada e de espectrofotometria no mercado (Seção 2.4) e estes equipamentos propiciam a realização de diversos exames na área da criminalística.

2.2. Introdução a Cores

Nesta seção tem-se as definições de elementos básicos e imprescindíveis para o entendimento sobre cores e refletâncias espectrais. A origem do conceito atual de cores deve-se à descoberta da natureza das cores por Isaac Newton nos anos de 1600. O experimento mostra que a luz branca pode ser dividida em cores individuais e que a luz de diferentes cores possui diferentes graus de refração. Estes estudos permitiram que fosse concluído que a luz consiste em energia de diferentes comprimentos de onda.

O olho humano é sensível a uma faixa de comprimento de onda aproximada de 380nm à 780nm, que representa somente uma pequena fração do espectro eletromagnético completo [GW00], conforme ilustrado na Figura 1.2. No espectro visível, certos comprimentos de onda originam certas sensações visuais, por exemplo, os comprimentos de onda mais curtos são percebidos como violeta e azul.

Todo o espectro eletromagnético pode ser representado como ondas, sendo o comprimento de uma onda representado pelo símbolo λ . Um comprimento de onda pode ser medido pela distância entre dois pontos comparados da onda (por exemplo, dois picos), conforme ilustrado na Figura 2.1. Os comprimentos de onda utilizados por este trabalho são considerados bem pequenos se comparados com medidas convencionais, aproximadamente 0,00000055 metros. Por este motivo são expressos em nm (nanômetros) o qual equivale a 10^{-9} metros.

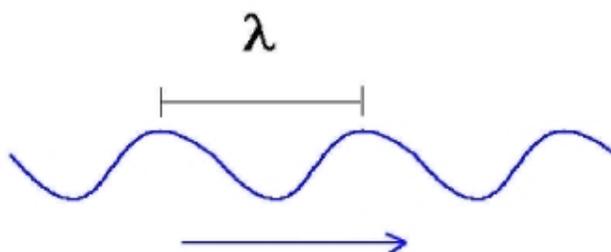


Figura 2.1: Representação do comprimento de onda (adaptado de [Col04])

A base para a observação de uma amostra é que exista uma fonte luminosa que incida sobre essa amostra. Quando da incidência desta luz, duas situações podem ocorrer:

- **Reflexão:** A reflexão é proveniente da mudança no índice de refração fazendo com que a luz seja refletida pela superfície. A luz que é refletida pelo material é chamada de reflexão especular.
- **Refração:** A refração é proveniente da absorção e passagem da luz pela superfície, ocasionada pela mudança do índice de refração, diminuindo a velocidade da luz. A luz que atravessa o material é chamada de luz transferida.

Através da compreensão sobre as propriedades de reflexão e refração das superfícies, pode-se concluir que a maioria dos objetos do mundo que conhecemos não são coloridos e

sim, que estes possuem diferentes propriedades de reflexão e refração, para diferentes comprimentos de ondas da luz.

2.3. Padrão CIE

A sigla CIE é a abreviação de *Commission Internationale de l'Eclairage*, o qual é o título em francês da Comissão Internacional sobre Luz. O CIE é uma organização voltada para cooperação internacional e troca de informações através de seus países membros, sobre todos os assuntos relacionados com a ciência e a arte da luz [CIE04]. O CIE tornou-se uma organização profissional e reconhecida como a maior autoridade no assunto, sendo reconhecida pela ISO como uma organização de padronização internacional. Nas sub-seções seguintes tem-se a descrição de definições da comissão CIE relevantes para este estudo.

2.3.1. Valores Triestímulos XYZ - CIE 1931

O olho humano possui receptores para comprimentos de onda curto, médio e longo, também conhecidos como receptores azul, verde e vermelho [Har03]. Esses valores unidos reproduzem uma sensação de cor no sistema humano. Um modelo de cores é um método específico de associar esses três valores (ou valores triestímulos). Conforme a *Colourware* [Col04], em 1931 a CIE desenvolveu um sistema para especificar o estímulo colorido, usando esses valores triestímulos para três primárias imaginárias X , Y e Z . O modelo de cores CIE XYZ (ou modelo CIE 1931) é um dos vários modelos de cores existentes, porém é considerado um modelo especial, pois serve como base para a definição de vários outros modelos e foi criado a partir da análise de observadores humanos. O sistema CIE XYZ criou uma observação padrão, que consiste em uma tabela que mostra o quanto de cada primária seria necessário para definir cada comprimento de onda da luz. Esta tabela foi criada a partir da média de resultados de observadores, que foram questionados à combinar comprimentos de onda monocromáticos da luz com misturas das 3 primárias. A Figura 2.2 demonstra a média dos resultados obtidos pelos observadores.

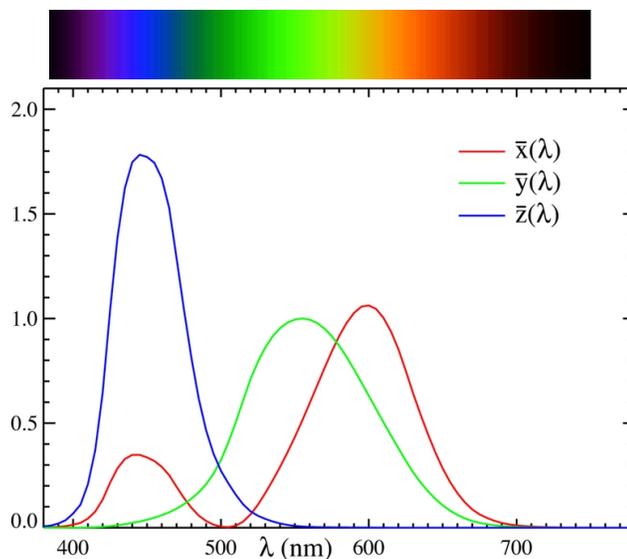


Figura 2.2: Funções das observações de combinação de cores CIE XYZ $\bar{x}(\lambda)$, $\bar{y}(\lambda)$ e $\bar{z}(\lambda)$ em nanômetros entre 380nm e 780nm em intervalos de 5nm (adaptado de [Wal04])

As quantidades das 3 primárias X , Y e Z , que especificam um estímulo de cor, são consideradas como componentes vermelho, verde e azul, respectivamente [Wal04]. Esses valores foram criados sobre as seguintes propriedades:

1. Os valores de X , Y e Z são positivos para todos os possíveis estímulos reais.
2. O valor do triestímulo Y é diretamente proporcional à luminosidade de uma combinação aditiva.
3. Para uma combinação de estímulos com igual energia tem-se que: $X = Y = Z$.

O espectro de emissão de uma fonte de luz e os espectros de transmissão, reflexão e absorção de uma superfície, normalmente são determinados por um espectrofotômetro e especificados como uma tabela de medidas de comprimentos de onda. Essas medidas normalmente possuem intervalos de 5nm dentro da faixa visual e são necessárias para o cálculo exato dos valores triestímulos X , Y e Z . Conseqüentemente, são utilizadas para a definição do espectro de refletância, denotado como $P(\lambda)$.

As funções de combinação de cores CIE XYZ $\bar{x}(\lambda)$, $\bar{y}(\lambda)$ e $\bar{z}(\lambda)$ (Figura 2.2), correspondem aos valores triestímulos X , Y e Z com incidência de uma fonte de luz com comprimento de onda λ . Essas funções são medidas através da percepção da cor média de

um observador humano sobre a faixa visível de $\lambda_{vio} = 380$ até $\lambda_{ver} = 780$, onde *vio* e *ver* representam as cores violeta e vermelho, respectivamente. Assim, o cálculo dos valores triestímulos X , Y e Z é realizado seguindo as Equações (2.1), (2.2) e (2.3) [Wal04].

$$X = \Delta\lambda \sum_{\lambda=\lambda_{ver}}^{\lambda_{vio}} \bar{x}_{\lambda} P(\lambda) \quad (2.1)$$

$$Y = \Delta\lambda \sum_{\lambda=\lambda_{ver}}^{\lambda_{vio}} \bar{y}_{\lambda} P(\lambda) \quad (2.2)$$

$$Z = \Delta\lambda \sum_{\lambda=\lambda_{ver}}^{\lambda_{vio}} \bar{z}_{\lambda} P(\lambda) \quad (2.3)$$

2.3.2. Diagrama de Cromaticidade CIE

Os valores triestímulos X , Y e Z podem ser apresentados graficamente através de uma representação em 3 dimensões (Figura 2.3). Deste diagrama em 3 dimensões o plano (X,Y) é chamado de diagrama de cromaticidade padrão CIE, conforme ilustrado na Figura 2.4.

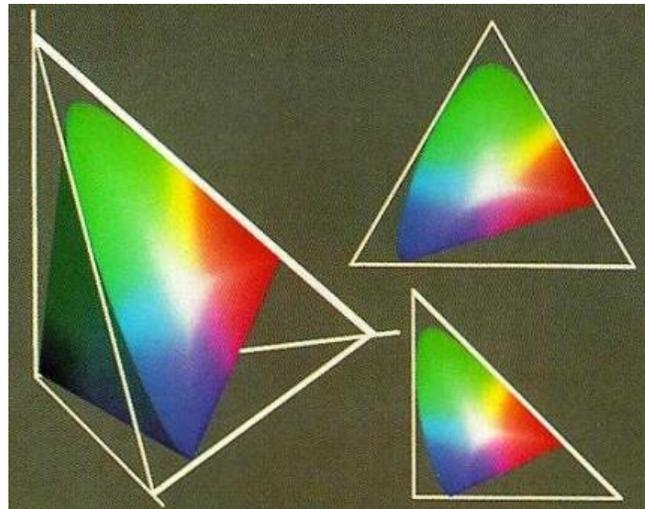


Figura 2.3: Diagramas padrão CIE. Esquerda: visão 3D do diagrama. Direita-acima: visão perpendicular do plano. Direita-baixo: projeção no plano (X,Y) , diagrama de cromaticidade. (adaptado de [Com03])

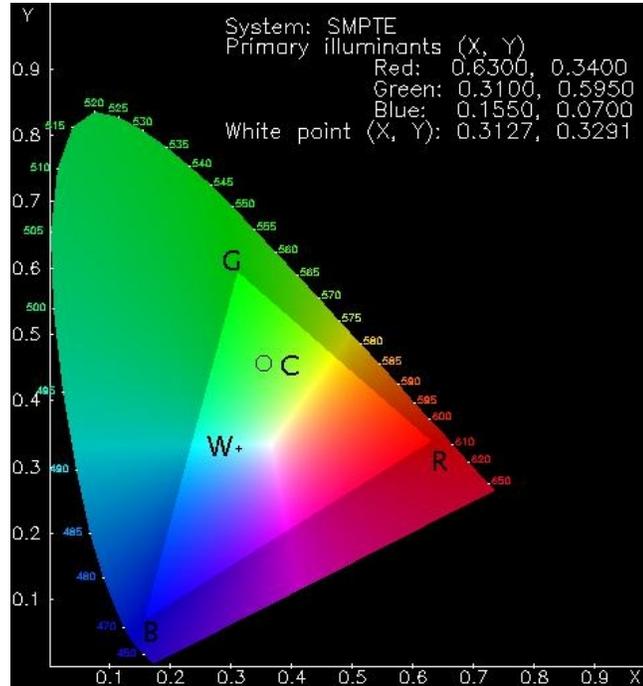


Figura 2.4: Diagrama de Cromaticidade CIE (adaptado de [Wal04])

A justificativa da possibilidade do diagrama de cromaticidade poder ser representado apenas pelo plano (X,Y) , considera a propriedade número 3 dos valores triestímulos e a normalização desses valores, conforme as equações (2.4) - (2.8).

$$x = \frac{X}{(X+Y+Z)} \quad (2.4)$$

$$y = \frac{Y}{(X+Y+Z)} \quad (2.5)$$

$$z = \frac{Z}{(X+Y+Z)} \quad (2.6)$$

Visto que,

$$x + y + z \equiv \frac{(X+Y+Z)}{(X+Y+Z)} \equiv 1 \quad (2.7)$$

Tem-se

$$z = 1 - (x + y) \quad (2.8)$$

A Figura 2.4 apresenta coordenadas de pontos respeitando o padrão SMPTE (*Society of Motion Picture and Television Engineers*). O SMPTE [SMP04] provê diversos padrões para televisão e cinema, dentre os padrões estão as definições de coordenadas de cores que são respeitadas por esta análise. A iluminação utilizada para a geração das coordenadas dos pontos foi a denominada *D65*. As iluminações são energias relativas normalmente tabuladas para cada faixa de comprimento de onda, conforme exemplos ilustrados na Figura 2.5 e na Figura 2.6. Existem vários tipos de iluminações que são utilizadas pela indústria de cores incluindo *A*, *C* e *D65*. As iluminações *A* e *C* foram definidas pelo CIE 1931 para representar a luz de tungstênio e a luz natural do dia respectivamente. A iluminação *C* foi julgada como uma representação pobre da luz do dia, sendo que esta contém energia insuficiente em ondas mais curtas, o que faz com que esta seja freqüentemente substituída por uma classe de iluminação conhecida como *D65*.

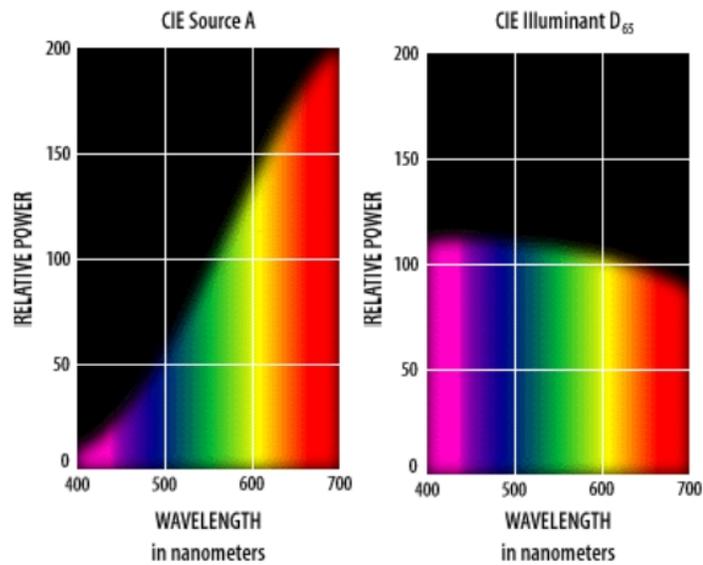


Figura 2.5: Energia relativa dos padrões CIE *A* e *D65*, respectivamente. (adaptado de [Har03])

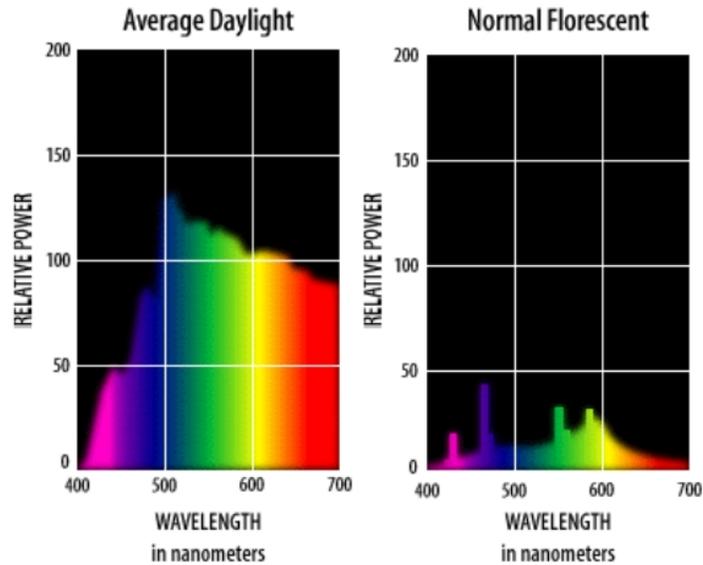


Figura 2.6: Energia relativa da média da luz do dia e de uma lâmpada fuorescente. (adaptado de [Har03])

Na Figura 2.4 nota-se que as cores espectrais puras encontram-se nas regiões de fronteira do gráfico (muitas vezes citado como “ferradura” ou “língua”). Os pontos R , G e B são as coordenadas das três primárias do modelo de cores RGB (Seção 2.5.1). O ponto W representa a coordenada de energia igual dos valores de triestímulos, onde existe a convergência de todas as energias do diagrama. O ponto C representa uma coordenada arbitrária que é composta por valores de R , G e B , ou seja, uma cor que pode ser representada no modelo RGB. A Figura 2.4 apresenta uma área triangular mais acentuada com vértices nos pontos R , G e B , esta região engloba as cores que podem ser representadas no modelo de cores RGB. A Figura 2.7 demonstra esta região considerando a visão dos 3 planos (X,Y) , (X,Z) e (Z,Y) .

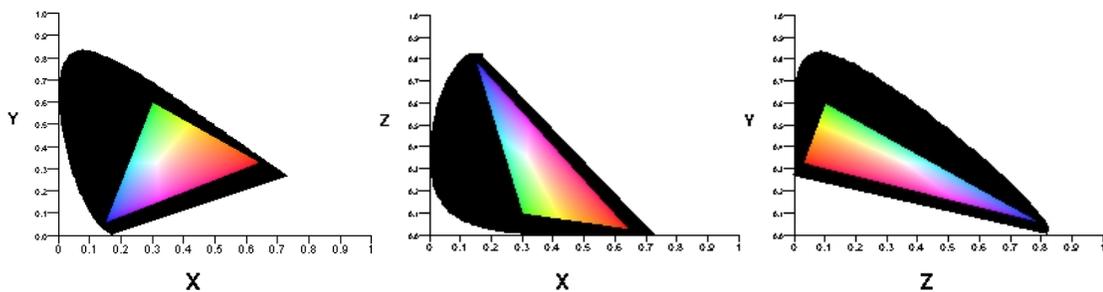


Figura 2.7: Cores do diagrama CIE que podem ser representadas no modelo de cores RGB. Planos (X,Y) , (X,Z) e (Z,Y) , respectivamente. (adaptado de [Zha05])

Para Gonzalez [GW00], qualquer ponto que esteja localizado nas regiões de fronteira do diagrama é considerado completamente saturado. Com o deslocamento do ponto da fronteira em direção ao ponto de energia igual W , este fica gradualmente menos saturado, ou seja, mais luz branca é adicionada à cor.

Conforme descrito anteriormente, as cores possíveis de serem representadas no modelo de cores RGB encontram-se na região triangular interna do diagrama (Figura 2.4). Com isto, nota-se o problema de uma conversão direta de uma cor representada no modelo XYZ, que se encontra fora da região triangular, para uma cor representada no modelo de cores RGB. A Figura 2.8 demonstra esse caso através de um ponto arbitrário C .

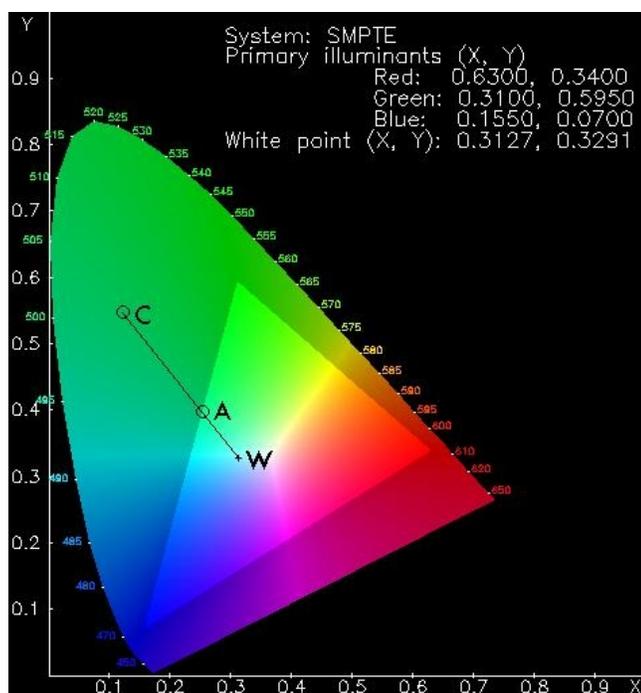


Figura 2.8: Diagrama de Cromaticidade CIE demonstrando uma coordenada C não representável diretamente no modelo de cores RGB (adaptado de [Wal04])

Para Walker [Wal04], o procedimento para a representação de um ponto que não se encontra dentro da região triangular do diagrama de cromaticidade, como por exemplo o ponto C (Figura 2.8), é reduzir a saturação do ponto gradativamente até que este possua coordenadas localizadas na fronteira da região triangular. Em outras palavras, o ponto deve “deslizar” em direção ao ponto de energia igual W até que este alcance uma coordenada representável no modelo de cores RGB. Com este procedimento, considerando valores

aproximados, todas as cores no espectro visível podem ser mapeadas para o modelo de cores RGB, conforme ilustrado na Figura 2.9.

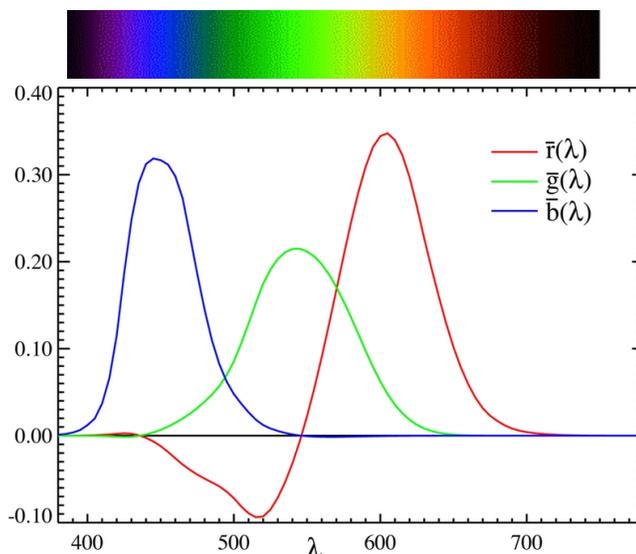


Figura 2.9: Valores RGB correspondentes aos comprimentos de onda visíveis de 380nm à 780nm (adaptado de [Wal04])

Comparando os valores dos componentes $\bar{x}(\lambda)$, $\bar{y}(\lambda)$ e $\bar{z}(\lambda)$ das observações sobre o modelo de cores CIE XYZ (Figura 2.2), com os valores dos componentes $\bar{r}(\lambda)$, $\bar{g}(\lambda)$ e $\bar{b}(\lambda)$ dos valores aproximados do modelo de cores RGB (Figura 2.9), nota-se através da escala dos gráficos que uma pequena quantidade de valores podem ser representados através do modelo de cores RGB, o que pode ser observado também através da Figura 2.7. Adicionalmente a Figura 2.9 ilustra que existe uma perda de informações nos casos onde algum dos componentes possui valor negativo, nestes casos o componente no modelo de cores RGB padrão é considerado com o valor zero.

2.4. Equipamentos Especializados

Conforme descrito na Seção 2.1.3, os procedimentos laboratoriais para identificar possíveis adulterações em documentos manuscritos são complexos e, em alguns casos, podem ser até impossíveis de realizar. Para este propósito normalmente equipamentos específicos de análise são utilizados, os quais podem utilizar o método VSC (*Video Spectral Comparison*) ou o método químico utilizando TLC (*Thin-Layer Chromatography*), [Nor05].

2.4.1. VSC - *Video Spectral Comparison*

Processo que utiliza imagens fotográficas obtidas através do uso de filtros e/ou iluminações que normalmente não são perceptíveis ao olho humano nu [Nor05]. A sigla VSC é utilizada tanto para *Video Spectral Comparison* quanto para *Video Spectral Comparator*, dependendo da literatura.

Este tipo de equipamento é composto por um conjunto de filtros espectrais, combinado com fontes luminosas e uma câmera fotográfica digital, conforme ilustrado na Figura 2.10.

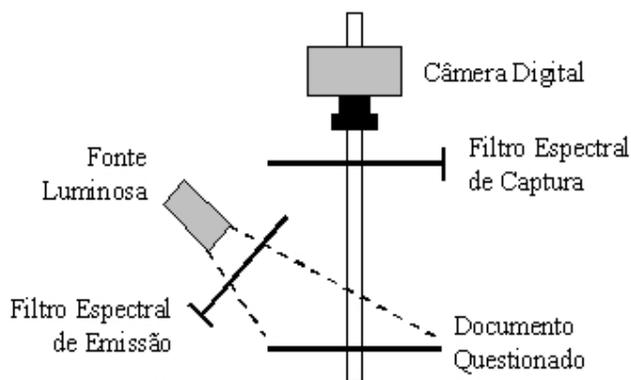


Figura 2.10: Sistema padrão de aquisição de imagem espectral

Existem diferentes tipos de equipamentos e com diferentes configurações, para análise de refletâncias, como por exemplo: a *Kappa Opto-Electronics Inc.* [Kap03] apresenta um equipamento digital com filtros que variam de 280nm à 1.000nm, onde pode-se obter imagens filtradas de uma dada amostra permitindo a identificação pelo operador de diferentes intensidades de refletância (Figura 2.11(a)). A *Melles Griot* [Mel03] apresenta um equipamento digital com filtros pré-definidos em 450nm, 485nm, 525nm e 570nm, onde pode-se analisar na própria imagem iluminada as diferenças de refletância (Figura 2.11(b)). E, a *Foster & Freeman* [FF03] apresenta um equipamento digital com filtros pré-definidos em 570nm, 590nm, 610nm, 630nm, 645nm, 665nm, 695nm, 715nm, 735nm, 780nm, 830nm, 850nm e 1.000nm, onde pode-se analisar na própria imagem iluminada as diferenças de refletância, possibilitando a análise do gráfico da refletância espectral que é mostrado no monitor do equipamento (Figura 2.11(c)).

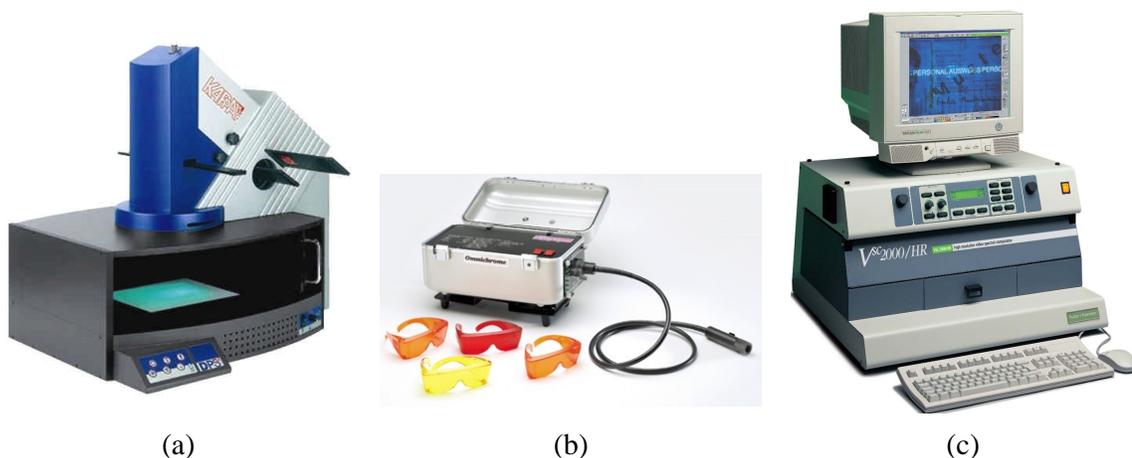


Figura 2.11: Fotos de alguns equipamentos especializados para análise de documentos questionados utilizando o método VSC. (a) DPS 3. (b) Omniprint 1000A. (c) VSC 2000/HR (adaptado de [Kap03], [Mel03] e [FF03], respectivamente)

A utilização destes equipamentos consiste basicamente na mudança das configurações da intensidade luminosa e dos filtros de captura e de incidência. A combinação destas configurações objetiva discriminar diferentes pigmentos de corante de tintas coloridas (Figura 2.12), dentre outros objetivos.

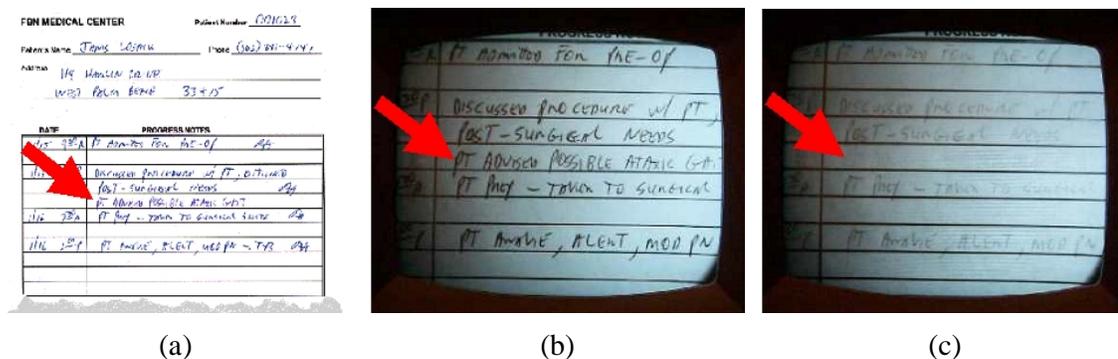


Figura 2.12: Resultado da aplicação do equipamento VSC-4 da *Foster & Freeman* [FF03] (adaptado de [Nor05]). (a) Registro médico questionado onde a seta indica a linha a ser analisada. (b) Área questionada no equipamento antes da aplicação de filtros IR. (c) Área questionada vista no comprimento de onda IR 795nm, onde nota-se a ausência de refletância sobre a linha questionada. (adaptado de [Nor05])

Os filtros da luz e da câmera são específicos para filtrar os raios que incidem e os raios que refletem na amostra, chamados de filtros de emissão e filtros de captura, respectivamente (Figura 2.10). Os filtros de emissão filtram os raios para que determinadas faixas de comprimento de onda incidam sobre a amostra, enquanto outras faixas ficam retidas no filtro.

Os filtros de captura retêm os raios de uma determinada faixa de comprimento de onda, deixando que apenas uma faixa específica seja digitalizada pela câmera.

Para a digitalização das imagens dos documentos questionados, utiliza-se normalmente uma câmera fotográfica digital. Basicamente, existem câmeras com dois tipos de sensores para digitalização: CCD (*Charge-Coupled Device*) e CMOS (*Complementary Metal-Oxide-Semiconductor*). Os sensores CCD podem ser sensíveis a cores ou a tonalidades de níveis de cinza. Os sensores CCD coloridos são normalmente utilizados em câmeras digitais convencionais e não são capazes de distinguir faixas muito próximas de frequência do espectro de cores. Os sensores CCD para tonalidades de cinza são utilizados em sistemas específicos de digitalização para analisar espectros de cores. Estes sensores representam informações em tons de cinza de 10 a 14 BPP (*Bits Per Pixel*) e a filtragem espectral é realizada através de filtros óticos acoplados às câmeras. Os sensores CMOS são sensíveis a cores e são utilizados em processos de análises espectrais, porém possuem normalmente um custo elevado.

Para que uma imagem da amostra possa ser digitalizada necessita ser iluminada por uma fonte de luz. Existem dois tipos de iluminação: por incidência e por transferência. A iluminação por incidência consiste em posicionar a fonte luminosa sobre a amostra, a fim de capturar os raios que são refletidos da mesma, conforme ilustrado na Figura 2.13(a). A iluminação por transferência consiste em posicionar a fonte luminosa no lado oposto da posição da câmera, desta forma os raios capturados são os que atravessam a amostra e incidem sobre a lente da câmera, conforme ilustrado na Figura 2.13(b).

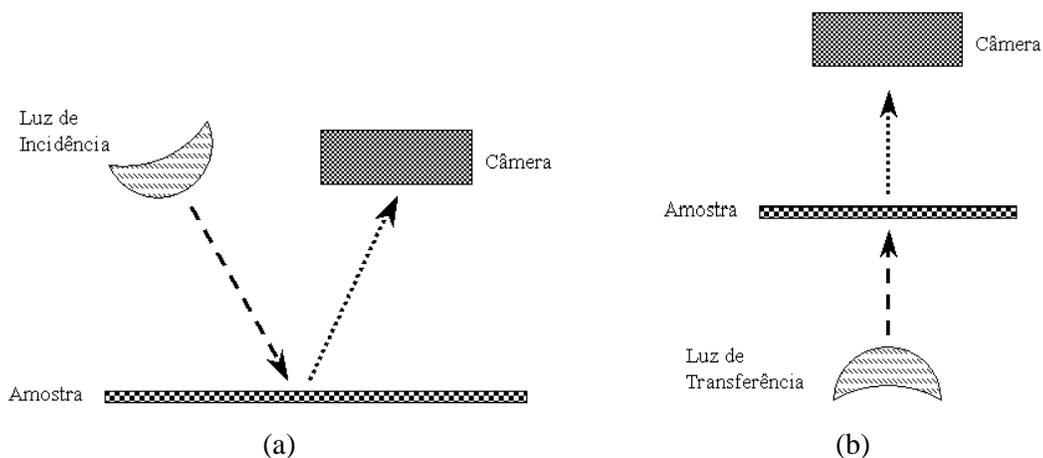


Figura 2.13: Tipos de iluminação: (a) Iluminação por Incidência. (b) Iluminação por Transferência.

Independentemente se a iluminação utilizada é por incidência ou por transferência, foram realizados estudos sobre os seguintes tipos de lâmpadas: infra-vermelho, ultra-violeta, fluorescentes e halógenas com filamento de tungstênio. Cada lâmpada emite ondas eletromagnéticas em uma determinada faixa de frequência, o que torna essas lâmpadas especialmente úteis para documentoscopia. As lâmpadas halógenas em particular, possuem a característica principal de emitirem ondas em uma grande faixa de comprimento de onda, de 300nm à 1.000nm.

O processo de iluminação por transferência requer a utilização de um vidro opaco para que haja um espalhamento da luz que atravessa o vidro e incide sobre o fundo da amostra. Isto é necessário para que regiões da amostra não sejam favorecidas por um maior nível de transferência de iluminação.

Visando um processo de aquisição de imagens rápido e com baixo custo, a proposta de equipamentos deste trabalho requer uma câmera fotográfica digital com sensores CCD e duas fontes luminosas com lâmpadas halógenas (Apêndice A).

2.4.2. TLC - *Thin-Layer Chromatography*

A análise de tintas utilizando TLC é um procedimento que utiliza análises físico-químicas para a definição de diferentes tipos de tintas [Nor05]. Em outras palavras, é um procedimento de separação micro-analítico no qual os componentes de uma mistura são transportados para diferentes distâncias em uma placa recoberta com uma fina camada de material poroso [Mic04]. Este procedimento é composto de diversos equipamentos específicos para análise, diferentemente do VSC que normalmente possui um equipamento principal e seus acessórios.

Um processo de cromatografia físico-química realiza-se através da migração diferencial dos componentes de uma mistura, que ocorre devido a diferentes interações das duas fases do processo [DCV98], [Cio03]:

- **Fase Estacionária:** Formada por um material próprio para reter, de forma diferenciada, os componentes da amostra que se deseja separar.

- **Fase Móvel:** Formada pelo material que se desloca pela fase estacionária, arrastando assim os componentes da amostra.

Existem diversos tipos de processos físico-químicos de cromatografia, os quais podem ser classificados através de quatro fatores [DCV98]:

- **Pela forma física do sistema cromatográfico:** Em relação à forma física empregada no sistema, este pode ser subdividido em: Cromatografia em Coluna e Cromatografia Planar.
- **Pela fase móvel empregada:** Em relação à fase móvel, este pode ser subdividido em: gasosa, líquida e supercrítica.
- **Pela fase estacionária empregada:** Em relação à fase estacionária, este pode ser subdividido em: sólidas, líquidas e quimicamente ligadas.
- **Pelo modo de separação:** Em relação ao modo que os componentes são separados, este pode ser subdividido em: adsorção, partição, troca iônica, exclusão ou misturas desses mecanismos.

Desta forma, o processo utilizando TLC é caracterizado como Planar (quanto à forma física), líquido-sólido (quanto às fases móvel e estacionária) e de adsorção (quanto ao modo de separação). Ou seja, o processo utiliza uma superfície de característica plana (forma física) como base para a execução do processo, normalmente é utilizada uma placa de vidro ou de alumínio [Mic04], chamada de placa TLC. A camada de componente (fase estacionária) que recobre a placa em geral é constituída de sílica gel. Um solvente líquido (fase móvel) é utilizado para arrastar a amostra dissolvida sobre a fase estacionária [Mic04]. E, a adsorção indica que a separação dos componentes (ou seja, sua aderência) é realizada pela diferença de afinidade dos componentes de uma mistura em relação à fase estacionária [DCV98].

Existem diferentes procedimentos empregados para a separação de amostras de tintas, porém suas diferenças estão relacionadas a alguns detalhes de configuração dos equipamentos [All98], [Mic04].

A Figura 2.14 demonstra uma fotografia real de um processo utilizando placa TLC sobre canetas típicas de cores vermelha, preta e azul. Nota-se que dependendo da tinta utilizada, os componentes aderem à fase estacionária em momentos diferentes.

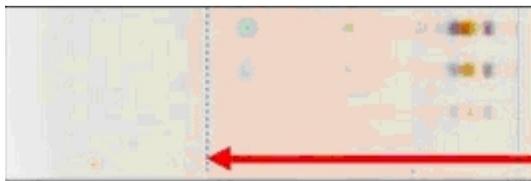


Figura 2.14: Ilustração real de resultados de um processo utilizando TLC (adaptado de [Mic04])

Este processo é considerado como o mais conclusivo para a análise de diferentes tintas, proporcionando um resultado pouco contestável [Nor05]. A principal desvantagem do processo é ser de natureza destrutiva, ou seja, as amostras necessitam ser retiradas do documento, o que representa que estas não podem ser reaproveitadas.

2.5. Modelos de Cores

Um modelo de cores, ou espaço de cores, facilita a especificação de cores respeitando um padrão de representação aceito pela comunidade científica. O modelo, além de representar as cores propriamente ditas, representa também os relacionamentos destas entre si. Mais especificamente, um modelo de cor é uma especificação de um sistema de coordenadas normalmente tridimensional e um subespaço dentro desse sistema, onde cada cor é representada por um único ponto.

Diferentes sistemas de processamento de imagem utilizam diferentes modelos de representação de cores. Dentre os modelos mais utilizados encontram-se: RGB, CMY, CMYK, YIQ, YUV, YCbCr, HSV, HSI, HLS, LHS, CIE-HLS e CIE-XYZ, [GW00], [Mai03]. A escolha de um ou mais modelos de cores para uma determinada aplicação depende de diversas variáveis, como por exemplo: área de atuação, tempo necessário para o processamento de imagens, informações relevantes da imagem para tratamento, condições ideais para o algoritmo de tratamento de imagens, entre outras.

Os estudos deste trabalho concentram-se basicamente nos modelos de cores RGB (*Red, Green e Blue*), CMYK (*Cyan, Magenta, Yellow e Black*), HSI (*Hue, Saturation e Intensity*), YIQ (*Y* representa a luminância e os componentes *I* e *Q* representam a cromaticidade, significando *Intermodulation* e *Quadrature*, respectivamente) e YUV (*Y* representa a luminância e os componentes *U* e *V* representam a cromaticidade), conforme descrito nas próximas sub-seções.

2.5.1. O Modelo de Cores RGB

O modelo RGB é o mais adequado e utilizado para a representação de cores em dispositivos de apresentação, como por exemplo, monitores e a maioria de aplicativos gráficos computacionais. Esta adequação justifica-se pelo modelo representar uma significativa porção do espectro de cores visíveis (Seção 2.3.1), através da mistura de suas três componentes primitivas *R*, *G* e *B* (*Red*, *Green* e *Blue*). Estas primitivas são chamadas de cores aditivas [GW00], as cores refletidas de um objeto iluminado com luz branca. As imagens no modelo de cores RGB podem reproduzir até 16.777.216 cores diferentes, utilizando 24 BPP. Estes fatores fazem com que as câmeras digitais, monitores de computadores e *scanners*, em sua maioria, tenham adotado este modelo de cores para a geração de suas imagens.

O modelo de cores RGB não é considerado um modelo de cores absoluto. Como a cor resultante é composta da mistura de cores primárias, podem existir variações das cores resultantes dependendo dos dispositivos de visualização utilizados. Por exemplo, dois monitores podem representar a mesma imagem com cores aparentemente diferentes, este fenômeno é conhecido como metamerismo.

Nota-se neste modelo que a leitura dos valores dos componentes não transmite uma idéia natural de qual cor será percebida. Toda cor associada a um *pixel* é representada pela adição de um terno de componentes primários (vermelho, verde e azul). Para Gonzalez [GW00], os três componentes são fortemente acoplados, de modo que uma variação no brilho sem alterar a cor, implica em uma variação não-linear em todos eles. Esta observação evidencia que não faz parte da linguagem natural descrever cores por esta terna.

Para Gonzalez [GW00], a representação do modelo RGB é feita através de um cubo em três dimensões, conforme ilustrado na Figura 2.15(a) e na Figura 2.15(b).

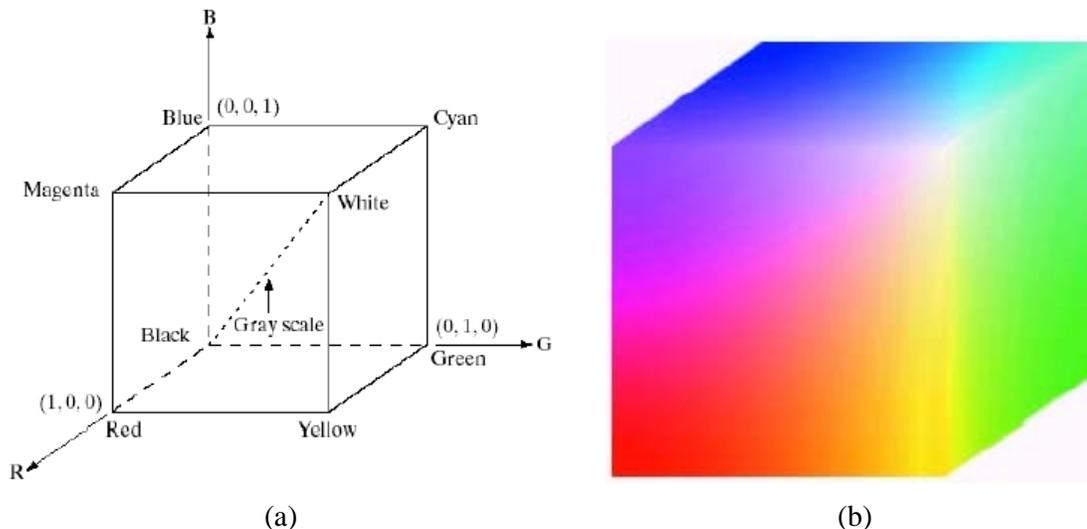


Figura 2.15: Representação tridimensional do modelo de cores RGB (adaptado de [Sob03]). (a) Representação das coordenadas. (b) Representação das cores.

2.5.2. O Modelo de Cores CMYK

O modelo de cores CMYK, também chamado de YMCK, é um modelo de cores subtrativas utilizado normalmente em impressões coloridas [GW00]. O modelo baseia-se na mistura de seus componentes (*Cyan*, *Magenta*, *Yellow* e *Black*) para criar diferentes cores. Todos os componentes do modelo de cores CMYK normalmente possuem valores compreendidos no intervalo $[0,1]$, inclusive.

O modelo CMYK originou-se do modelo de cores CMY, o qual representa as três componentes primitivas subtrativas. Quando uma iluminação branca incide sobre uma tinta, parte do espectro é absorvido e parte é refletido. Conforme visto anteriormente, as cores que conseguimos ver em algum objeto são as cores refletidas por este. No caso do modelo CMY, este representa as cores que são absorvidas pelo objeto [GW00]. Teoricamente, estes três componentes combinados absorvem todas as cores e produzem a cor preta (Figura 2.16(b)). Por esta razão este modelo é chamado de modelo subtrativo.

Em outras palavras, a cor que um objeto aparenta ter é a parte do espectro que o objeto não absorveu, ou seja, o que ele refletiu [GW00]. Desta forma, as cores subtrativas são definidas como qualquer cor que não seja aditiva, ou seja, as cores absorvidas pelo objeto.

A Figura 2.16(a) ilustra as possíveis combinações das três componentes primitivas aditivas completamente saturadas. Nota-se que considerando combinações por pares de componentes tem-se as cores subtrativas e considerando a combinação do terço de componentes tem-se a cor branca pura. A Figura 2.16(b) ilustra as possíveis combinações das três componentes primitivas subtrativas completamente saturadas. Nota-se que considerando combinações por pares de componentes, tem-se as cores aditivas e considerando a combinação do terço de componentes tem-se, teoricamente, a cor preta pura.

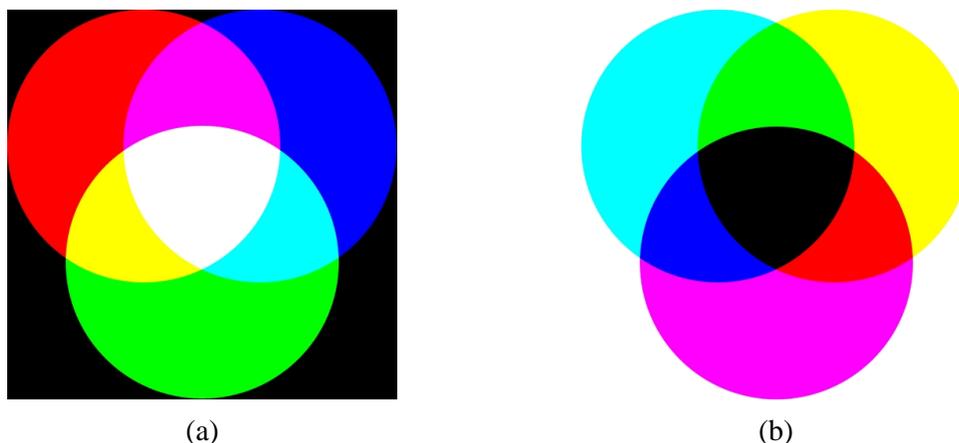


Figura 2.16: Mistura de Cores (adaptado de [Har03]). (a) Aditivas. (b) Subtrativas.

Como o modelo de cores RGB, o modelo CMY também não é considerado um modelo de cores absoluto. Como a cor resultante é composta da mistura de cores primárias, podem existir variações das cores resultantes dependendo dos dispositivos de visualização utilizados. O CMY também apresenta a característica de forte acoplamento entre seus componentes, como salientado no modelo de cores RGB (Seção 2.5.1).

Em algumas situações anteriores, fez-se necessário salientar que a combinação das três cores subtrativas gera a cor preta apenas na teoria. Explica-se tal afirmação pelo fato de que geralmente as cores subtrativas são utilizadas para impressões, o que necessita de corantes que normalmente possuem impurezas. Esta constatação conclui que a intenção de impressão da cor preta pela combinação das três componentes subtrativas gera, na maioria dos casos, uma cor próxima à cor preta. Para contornar tal situação criou-se o modelo de cores CMYK, o qual possui o quarto componente *K* (*black*), que misturado com os componentes *C*, *M* e *Y* possibilita a criação da cor preta pura.

2.5.3. O Modelo de Cores HSI

O modelo de cores HSI representa as cores de uma maneira mais próxima ao sistema de percepção visual humano [GW00]. Por exemplo, quando visualiza-se a cor rosa não pensa-se que esta cor é uma composição de grande parte de vermelho e partes iguais de verde e azul adicionadas e sim, pensa-se que é uma tonalidade (saturação) do vermelho (matiz), realizando uma comparação com o modelo de cores RGB.

O modelo HSI possui três componentes representativos: H (matiz), S (saturação) e I (intensidade). Sendo que:

- **Matiz:** Determina a cor básica refletida ou transmitida por um objeto. O valor da matiz é representado como uma localização em um círculo padrão de cores, tendo valores angulares compreendidos entre 0 e 360 graus. Este valor informa geometricamente a cor de um determinado *pixel*. A variação desse ângulo faz com que possam ser representadas todas as cores puras, sem a adição de saturação e intensidade.
- **Saturação:** Determina o grau no qual a cor não está diluída no branco, ou seja, a pureza da cor. Possui variação de 0 (0%) a 1 (100%). Uma saturação de valor 1 torna a cor com a definição pura da matiz (completamente saturada). Com a diminuição da saturação a cor tende a ficar cada vez mais acinzentada.
- **Intensidade:** Determina o brilho da cor e possui uma variação de 0 a 1. Uma intensidade de valor 0 sempre representa a cor preta e uma intensidade 1 sempre produz a cor branca, ignorando assim nestes casos os valores de matiz e saturação. Os valores intermediários determinam a quantidade de luminosidade adicionada à cor.

Estes componentes são representados em um modelo tridimensional em forma de dois cones superpostos inversamente, conforme ilustrado nas Figura 2.17(a) e Figura 2.17(b).

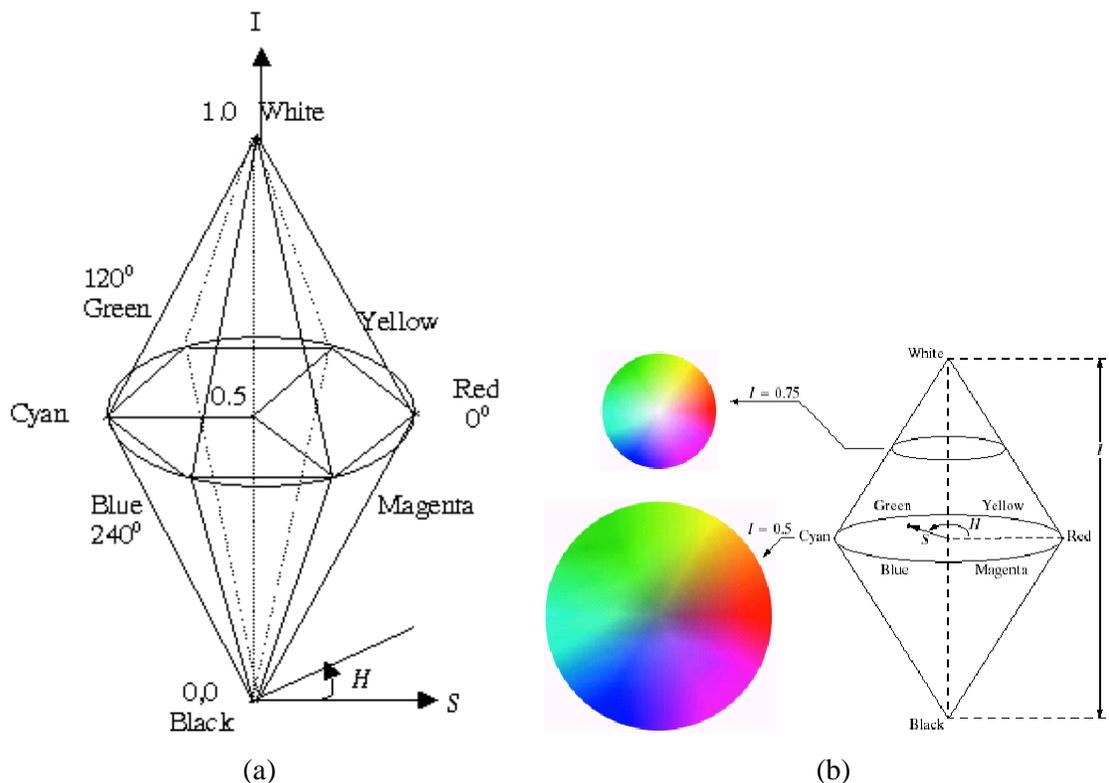


Figura 2.17: Representação tridimensional do modelo de cores HSI. (a) Representação das coordenadas (adaptado de [Mai03]). (b) Representação das cores (adaptado de [Sob03]).

Conforme Mai [Mai03], a principal característica do modelo HSI, no que se refere à compreensão de cores, está na não necessidade de saber qual a quantidade das cores primárias é necessária para a composição de uma determinada cor, antagonicamente aos modelos RGB e CMYK. Existem diversos modelos chamados HS x , onde x representa uma letra que determina o método de obtenção do brilho da imagem. A principal vantagem do uso dos modelos HS x , no que se refere ao processamento de imagens, está na qualidade desacoplada dos componentes. O componente x , especificamente, é utilizado para processos de segmentação, operações com histogramas, manipulações de intensidade e convoluções, por exemplo. Alguns dos exemplos de utilização do modelo HSI podem ser encontrados em processos de seleção e inspeção de frutas, verduras e objetos em geral [Ala03] e em processos de segmentação [BBF⁺97]. O uso do modelo de cores HSI justifica-se pela alta flexibilidade fornecida pelo sistema em relação aos demais, no que diz respeito principalmente à manipulação de cores e variações de luminosidade.

2.5.4. Os Modelos de Cores YUV e YIQ

O modelo de cores YUV é utilizado no sistema de codificação televisivo colorido PAL [Har03]. Este sistema é utilizado pela maioria dos países da Europa e alguns outros. A primitiva Y do modelo representa o componente de luminância e as primitivas U e V representam os componentes de cromaticidade.

O modelo de cores YIQ é utilizado no sistema de codificação televisivo colorido NTSC [Har03]. Este sistema é utilizado pelos Estados Unidos da América, pela maioria dos países Americanos e alguns outros. A primitiva Y do modelo representa o componente de luminância e as primitivas I e Q (*Intermodulation* e *Quadrature*, respectivamente) representam os componentes de cromaticidade.

Os dois modelos são uma re-codificação do modelo RGB, visando aumentar a eficiência no envio de informações e manter uma compatibilidade com os padrões monocromáticos de televisores. Ambos foram criados para utilizar melhor a capacidade do ser humano de sentir mais fortemente as diferenças de luminâncias, do que as diferenças de matiz e saturação [Har03]. Desta forma, a representação nestes modelos necessita de maior precisão para a representação do componente Y , do que para a representação dos demais componentes.

Para Gonzalez [GW00], como no modelo HSI (Seção 2.5.3), os componentes dos modelos de cores YIQ e YUV são desacoplados. Isto significa que possíveis variações de luminância, por exemplo, não afetam todos os componentes do modelo.

Considerando o modelo YUV, os componentes U e V podem ser representados em um sistema de coordenadas bidimensional (Figura 2.18). Os componentes I e Q do modelo YIQ também podem ser representados pelo mesmo sistema, inclusive gerando o mesmo gráfico, porém os valores são rotacionados 33° em relação aos componentes V e U . Em outras palavras, utilizar os componentes I e Q é apenas outra maneira de localizar um ponto no plano U e V .

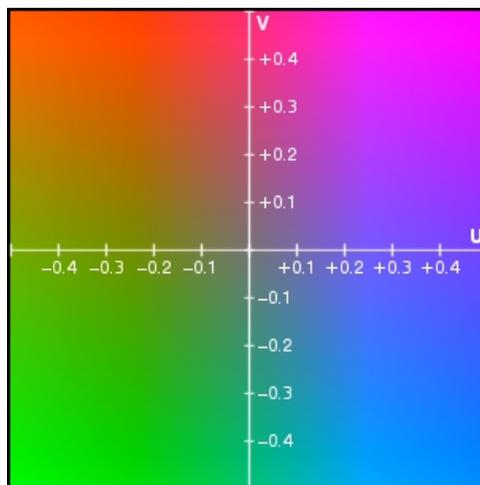


Figura 2.18: Plano $U-V$, $Y=5$, representado com cores do modelo RGB (adaptado de [Den05])

A compatibilidade com os padrões monocromáticos de televisores mencionada anteriormente, que esses dois modelos de cores oferecem, deve-se ao fato que o componente Y dos modelos retêm todas as informações necessárias para este tipo de aparelho. Este componente normalmente é utilizado para processamentos que necessitem de imagens em níveis de cinza com melhores definições de contraste.

2.5.5. Níveis de Cinza

As imagens em níveis de cinza representam normalmente as informações referentes à intensidade de luz de cada *pixel* em uma determinada banda do espectro eletromagnético [GW00]. Estas imagens são compostas das variações entre as cores preta e branca, representando assim diferentes tonalidades de cinza, conforme ilustrado na Figura 2.19



Figura 2.19: Exemplo de tonalidades em níveis de cinza

O padrão de representação de imagens em níveis de cinza determina que cada *pixel* possui até 256 valores diferentes. Desta forma, estas imagens podem reproduzir até 256 tonalidades diferentes de cinza, utilizando 8 BPP. Porém existem outros padrões para

representação que utilizam 10, 12 ou até 16 BPP, fazendo com que as imagens possam representar mais tonalidades individuais de cinza.

A representação de imagens em níveis de cinza permite que os valores dos *pixels* sejam dispostos em um modelo linear [Cas96]. Desta forma, pode-se definir que o grau de luminosidade empregado é proporcional ao nível de cinza da imagem analisada.

2.6. Conversões entre Modelos de Cores

Os modelos de cores apresentados neste trabalho permitem com que sejam formulações específicas para conversões. Esta seção demonstra as formulações necessárias para conversões do modelo de cores RGB para os modelos HSI, CMYK, YIQ e YUV. As conversões inversas não são utilizadas por este estudo.

Adicionalmente, esta seção demonstra métodos utilizados para a geração de uma imagem em níveis de cinza, a partir de uma imagem colorida.

2.6.1. Conversão do Modelo RGB para o CMYK

Todas as fontes analisadas para o processo de conversão, sugerem a utilização do modelo de cores CMY como padrão intermediário para conversão entre RGB e CMYK, conforme [Eas05], por exemplo.

Como mencionado anteriormente (Seção 2.5.2), os valores das quatro componentes do modelo de cores CMYK então compreendidos no intervalo $[0,1]$, inclusive. Desta forma, é necessário que os valores dos componentes do modelo de cores RGB sejam normalizados neste mesmo intervalo, conforme definido na Equação (2.9).

$$\begin{aligned} r &= R/255 \\ g &= G/255 \\ b &= B/255 \end{aligned} \tag{2.9}$$

A normalização dos valores R , G e B é armazenada nas variáveis r , g e b , respectivamente.

A transformação do modelo RGB para o modelo CMY é definida na Equação (2.10), [GW00] e [Eas05].

$$\begin{bmatrix} C' \\ M' \\ Y' \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} r \\ g \\ b \end{bmatrix} \quad (2.10)$$

Através da Equação (2.10) nota-se que a luz refletida de uma superfície coberta inteiramente com amarelo puro não contém o azul, visto que $Y' = 1 - b$. A mesma propriedade conclui-se dos demais componentes C' e M' .

Para realizar a conversão do modelo de cores CMY para o modelo de cores CMYK deve-se primeiro calcular o valor do componente K , como segue:

$$K = \min(C', M', Y') \quad (2.11)$$

Considerando a Equação (2.11), caso o valor do componente K for 1, os demais componentes C , M e Y possuem todos o valor 0. Caso contrário, serão consideradas as Equações (2.12) - (2.14) para calcular os valores destes.

$$C = \frac{C' - K}{1 - K} \quad (2.12)$$

$$M = \frac{M' - K}{1 - K} \quad (2.13)$$

$$Y = \frac{Y' - K}{1 - K} \quad (2.14)$$

2.6.2. Conversão do Modelo RGB para o HSI

A conversão do modelo de cores RGB para o modelo de cores HSI utilizado neste trabalho foi definido por Gonzalez [GW00]. O processo de conversão prevê um pré-requisito, a normalização dos valores de R , G e B para que representem valores entre 0 e 1, ou seja,

$$\begin{aligned}
0 &\leq R \leq 1 \\
0 &\leq G \leq 1 \\
0 &\leq B \leq 1
\end{aligned}
\tag{2.15}$$

A normalização dos valores R , G e B é armazenada nas variáveis r , g e b , respectivamente, conforme definido pelas Equações (2.16) - (2.18).

$$r = \frac{R}{(R + G + B)} \tag{2.16}$$

$$g = \frac{G}{(R + G + B)} \tag{2.17}$$

$$b = \frac{B}{(R + G + B)} \tag{2.18}$$

Além de garantir que os valores de r , g e b estão no intervalo $[0,1]$, as Equações (2.16), (2.17) e (2.18) afirmam que:

$$r + g + b = 1 \tag{2.19}$$

Depois dos valores de R , G e B estarem normalizados nas variáveis r , g e b , a aplicação das Equações (2.20) - (2.24) definirá os valores das variáveis H , S e I .

$$I = \frac{1}{3}(r + g + b) \tag{2.20}$$

$$S = 1 - \frac{3}{(r + g + b)} [\min(r, g, b)] \tag{2.21}$$

$$H' = \cos^{-1} \left\{ \frac{\frac{1}{2}[(r - g) + (r - b)]}{\left[(r - g)^2 + (r - b)(g - b) \right]^{\frac{1}{2}}} \right\} \tag{2.22}$$

Ressalta-se que a Equação (2.22), atende ao intervalo $0^\circ \leq H' \leq 180^\circ$. Desta forma, tem-se o valor da matiz H definido na Equação (2.23).

$$H = H' \quad (2.23)$$

Caso contrário, se $b > g$, então o valor de H deve ser maior que 180° . Neste caso, o valor final da matiz H define-se pela Equação (2.24).

$$H = 360^\circ - H' \quad (2.24)$$

2.6.3. Conversão do Modelo RGB para o YUV

A conversão do modelo de cores RGB para o modelo YUV possui como pré-requisito que os valores dos componentes R , G e B sejam normalizados. Esse processo é realizado com a utilização da Equação (2.9), gerando os valores normalizados nas variáveis, r , g e b , respectivamente.

O cálculo de conversão é realizado através da atribuição de pesos para os valores das variáveis r , g e b que são somados para produzir o valor do componente Y , conforme Equação (2.25). Os valores dos componentes U e V são obtidos através da subtração do componente Y das variáveis b e r respectivamente e da multiplicação por pesos para ajuste de escala. Conforme demonstrado nas Equações (2.26) e (2.27).

$$Y = 0,299r + 0,587g + 0,114b \quad (2.25)$$

$$U = 0,492(b - Y) \quad (2.26)$$

$$V = 0,877(r - Y) \quad (2.27)$$

Realizando as devidas substituições de valores nas Equações (2.26) e (2.27), tem-se a seguinte representação da fórmula de conversão em notação matricial:

$$\begin{bmatrix} Y \\ U \\ V \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ -0,147 & -0,289 & 0,436 \\ 0,615 & -0,515 & -0,100 \end{bmatrix} \begin{bmatrix} r \\ g \\ b \end{bmatrix} \quad (2.28)$$

2.6.4. Conversão do Modelo RGB para o YIQ

A conversão do modelo de cores RGB para o modelo YIQ possui como pré-requisito que os valores dos componente R , G e B sejam normalizados. Esse processo é realizado com a utilização da Equação (2.9), gerando os valores normalizados nas variáveis, r , g e b , respectivamente.

O cálculo de conversão é realizado através da atribuição de pesos para os valores das variáveis r , g e b que são somados para produzir o valor do componente Y , conforme Equação (2.29). Os valores dos componentes I e Q são obtidos através da subtração do componente Y das variáveis r e b e da multiplicação dos resultados das subtrações por pesos para ajuste de escala. Conforme demonstrado nas Equações (2.30) e (2.31).

$$Y = 0,299r + 0,587g + 0,114b \quad (2.29)$$

$$I = 0,735514(r - Y) - 0,267962(b - Y) \quad (2.30)$$

$$Q = 0,477648(r - Y) + 0,412626(b - Y) \quad (2.31)$$

Realizando as devidas substituições de valores nas Equações (2.30) e (2.31), tem-se a seguinte representação da fórmula de conversão em notação matricial:

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ 0,595716 & -0,274453 & -0,321263 \\ 0,211456 & -0,522591 & 0,311135 \end{bmatrix} \begin{bmatrix} r \\ g \\ b \end{bmatrix} \quad (2.32)$$

2.6.5. Conversão para Níveis de Cinza

A obtenção de uma imagem em níveis de cinza pode ser realizada utilizando dispositivos físicos ou realizando a conversão de imagens coloridas para níveis de cinza. Existem diversos métodos para esta conversão, os de interesse para esse trabalho estão descritos e ilustrados nesta seção.

Um método de conversão utilizado por muitas aplicações é o cálculo da média aritmética dos três componentes do modelo de cores RGB [Mai03], [Efg05]. O resultado deste método gera um valor de intensidade I , conforme definido na Equação (2.33). Comparando a Equação (2.20) da Seção 2.6.2 de conversão do modelo de cores RGB para o HSI e a Equação (2.33), nota-se que os resultados obtidos são os mesmos. Desta forma, pode-se afirmar que o método de conversão de imagens coloridas para níveis de cinza através da média aritmética dos componentes R , G e B , é a utilização direta do componente I do modelo de cores HSI. A geração da imagem em níveis de cinza consiste na utilização do valor resultante de intensidade I para a geração do nível de cinza do *pixel* analisado.

$$I = \frac{1}{3}(r + g + b) \quad (2.33)$$

Conforme descrito na Seção 2.5.3 sobre o modelo de cores HSI, a variação de valores do componente S define o quanto a cor do *pixel* encontra-se saturada. Caso o valor de S seja 0, a cor do *pixel* é considerada sem saturação, ou seja, a cor é representada apenas em níveis de cinza [GW00]. Assim, um método de conversão de uma imagem colorida para níveis de cinza pode ser definido através dos seguintes passos:

- Conversão de todos os *pixels* da imagem original, que encontra-se originalmente no modelo de cores RGB, para o modelo de cores HSI;
- Atualização de valor do componente S de todos os *pixels* da imagem para que possuam o valor 0, e;
- Conversão de todos os *pixels* da imagem no modelo de cores HSI para o modelo de cores RGB.

Analisando as equações da Seção 2.5.3, nota-se que atribuir o valor 0 para o componente S e utilizar o valor puro do componente I , ambos do modelo HSI, gera-se o mesmo resultado. Se $S = 0$, o valor angular da matiz H é desconsiderado, visto que qualquer valor de *pixel* obrigatoriamente reside sobre o eixo perpendicular aos cones superpostos, o eixo do componente intensidade I . Assim, a retirada da saturação das cores de uma imagem produz um resultado em níveis de cinza igual ao método do cálculo da média aritmética dos três componentes do modelo de cores RGB.

O método de conversão utilizado pela maioria dos sistemas e utilizado por todas as referências consultadas para este trabalho, baseia-se no uso das fórmulas dos modelos de cores YUV ou YIQ dos padrões televisivos NTSC e PAL [Mai03], [Efg05], por exemplo. A conversão baseia-se no cálculo do componente Y do modelo YUV ou do modelo YIQ, conforme a Equação (2.34). Comparando as Equações (2.25) e (2.29), onde tem-se os cálculos dos componentes Y dos modelos YUV e YIQ respectivamente, nota-se que a fórmula é a mesma para os dois modelos. Conforme descrito na Seção 2.5.4, a única diferença entre os dois modelos encontra-se na rotação dos valores dos componentes U e V em relação aos componentes I e Q , quando representados em um plano bidimensional. Desta forma, este método de conversão pode utilizar qualquer um dos modelos para a geração de imagens em níveis de cinza.

$$Y = 0,299r + 0,587g + 0,114b \quad (2.34)$$

Para *Efg's Computer Lab* [Efg05] os pesos empregados na Equação (2.34) refletem a sensibilidade à luz do olho humano para perceber cores primárias.

Analisando a Equação (2.34), conclui-se outro método para conversão. Algumas aplicações utilizam apenas o componente G do modelo de cores RGB para converter a imagem para níveis de cinza [Mai03]. A justificativa do uso deste componente deve-se ao fato deste ser o mais significativo para o cálculo da luminância Y .

Em termos gerais, qualquer componente de qualquer modelo de cores pode gerar uma imagem em níveis de cinza porém, dependendo do componente, seu valor deve ser normalizado. Com isso, o resultado destas conversões pode ser útil dependendo da importância e do tipo de informação representada pelo componente.

Em alguns casos, apenas o processo de conversão para níveis de cinza pode gerar resultados com pouca definição de contraste. Para aumentar o contraste destas imagens existem métodos que trabalham com uma redistribuição dos valores do histograma da imagem [Efg05]. Porém, como estes métodos alteram os valores dos *pixels* da imagem, algumas características importantes da imagem original são perdidas. Assim, alguns métodos de processamento de imagens podem apresentar resultados errôneos processando tais imagens. Um exemplo de método que redistribui os valores do histograma da imagem é a própria equalização do histograma [GW00].

2.7. Reconhecimento de Padrões

O Reconhecimento de Padrões em processamento de imagens digitais é um dos métodos da sub-área de Visão Computacional, que por sua vez é uma ramificação da área de Inteligência Artificial [Cas96]. O propósito da Visão Computacional é o desenvolvimento de algoritmos para a análise do conteúdo de imagens [Cas96].

O reconhecimento é considerado como uma habilidade básica dos seres humanos, pois recebem os dados do mundo através de seus sentidos e são capazes de reconhecer as fontes dos dados, quase que imediatamente [TG74], [Hay01].

Para Tou e Gonzalez [TG74], um padrão é a descrição de um objeto. Rasha [Ras94] detalha mais o conceito de padrão, definindo que esta descrição de um objeto pode ser um conjunto de medidas ou observações, normalmente representadas através de um vetor ou notação de matriz.

Para Santos [San04], o reconhecimento de padrões pode ser definido como a categorização de dados de entrada em classes identificáveis, via extração de características significantes ou atributos de detalhes relevantes. De acordo com Rasha [Ras94], um sistema básico de reconhecimento de padrões pode ser dividido em duas fases: a extração de características e a classificação. Estas duas fases são ilustradas na Figura 2.20 e são descritas nas Seções 2.7.1 e 2.7.2, respectivamente.

Conforme Haykin [Hay01], um modelo genérico de reconhecimento de padrões é definido na Figura 2.20. Um padrão é definido por um conjunto de m -observações, podendo ser representado por um ponto x em um espaço de observações m -dimensional. A extração de

características, descrita na Seção 2.7.1, mapeia o ponto x para um ponto intermediário y em um espaço de características q -dimensional, sendo $q < m$. O processo de classificação analisa e mapeia o ponto intermediário y para uma das classes em um espaço de decisão r -dimensional, sendo r o número de classes em que os padrões são possíveis de serem categorizados.

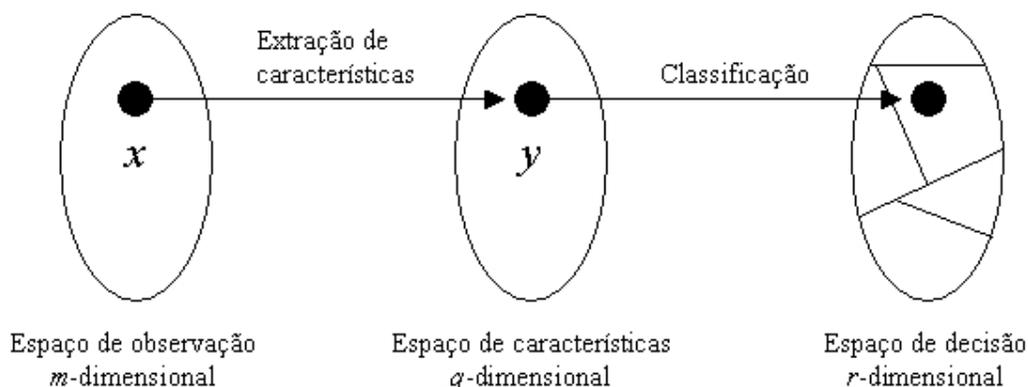


Figura 2.20: Modelo genérico do método de reconhecimento de padrões (adaptado de [San04])

Conforme Gonzalez [GW00], o estado da arte em análise computadorizada de imagens está, em sua maior parte, baseado em formulações heurísticas projetadas para resolver problemas específicos. O estudo em questão não é uma exceção, conforme definido na Seção 4, onde descreve-se o método proposto. Alguns exemplos de áreas que utilizam processos de reconhecimento automático de padrões são relacionados como segue: reconhecimento de voz, reconhecimento de textos em documentos eletrônicos, reconhecimento de códigos postais escritos à mão, reconhecimento de faces humanas, entre outras.

2.7.1. Extração de Características

A extração de características é a primeira fase de um sistema básico de reconhecimento de padrões [Ras94]. As características dos padrões são informações particulares de cada elemento a ser classificado que, de certa forma, devem diferenciar um elemento do outro. Adicionalmente, Santos [San04] define características como quaisquer medidas extraíveis de um padrão que podem contribuir para a classificação.

É necessária a definição de um conjunto de características suficiente para que os valores de cada elemento possam diferenciá-lo dos demais. A quantidade de características escolhidas reflete a quantidade de dimensões do espaço de características [Hay01], conforme ilustrado na Figura 2.20.

A seleção das melhores características para distinção de diversas classes pode ser um processo difícil, muitas vezes exigindo significantes processos computacionais [San04]. Para [Ras94], as características escolhidas devem respeitar os seguintes fatores:

- Ser computacionalmente possível de ser extraído;
- Conduzir a poucos erros de classificação, e;
- Reduzir a quantidade de informação manipulada, sem perder desempenho.

A escolha das características pode ser um processo de observação e criação de heurísticas, ou pode ser um processo exaustivo de geração e comparação de resultados com diversas combinações de características, a fim de encontrar a combinação que apresenta o melhor resultado.

2.7.2. Classificação

O processo de classificação é o objetivo fundamental do reconhecimento de padrões [San04]. Este processo consiste em analisar os dados do espaço de características e decidir com qual classe cada elemento será relacionado no espaço de decisão, conforme ilustrado na Figura 2.20.

De acordo com Justino [Jus01], existem dois tipos principais de métodos formais para classificação:

- **Métodos Estatísticos:** utilizam-se de informações estatísticas para a medição do espaço métrico para a realização de decisões. Existem dois principais tipos de métodos estatísticos [Jus01]:
 1. **Paramétrico:** considera que as classes possuem comportamentos probabilísticos conhecidos e que seus parâmetros de estimação possuem, normalmente, um comportamento Gaussiano.

2. **Não-paramétrico:** assume que não existe conhecimento *a priori* referente ao comportamento de formação das probabilidades das classes. Neste caso, os algoritmos desenvolvidos devem determinar um limiar de decisão ideal para a classificação.
- **Métodos Estruturais:** mapeiam características geométricas de maneira estruturada. As decisões são tomadas normalmente através do casamento de cadeias ou em modelos que simulam sentenças de uma linguagem artificial [GW00]. Existem dois principais tipos de métodos estruturais [Jus01]:
 1. **Métodos estruturais propriamente dito:** utilizam-se de um grafo para a representação das formas e das relações que estas possuem entre si. O processo de decisão consiste no casamento destas cadeias com cadeias pré-definidas por treinamento, ou por definições *a priori*.
 2. **Métodos sintáticos:** representam as formas através de padrões simbólicos, normalmente em listas de dados. Estas listas são consideradas como sentenças de uma linguagem artificial, onde os componentes representam elementos da forma a descrever. O processo de decisão utiliza regras sintáticas para a análise das listas.

Ressalta-se que o método de representação das informações mapeadas no espaço de características (Figura 2.20) difere conforme o método de classificação [GW00]. Para métodos estatísticos normalmente representa-se as características na forma de um vetor ou matriz de valores. Para métodos estruturais normalmente utiliza-se cadeias, listas, grafos ou árvores.

Depois de escolhido o método de classificação mais apropriado para o tipo de informação que será classificada, é necessário definir qual modelo de reconhecimento de padrões será utilizado, dependendo da disponibilidade do conhecimento *a priori* de informações sobre as classes as quais deseja-se distinguir. Os modelos de reconhecimento de padrão existentes são [TG74]:

- **Supervisionado:** Utilizado quando existem disponíveis informações representativas sobre as classes consideradas. Neste modelo o processo “aprende” sobre as classes através de um conjunto de padrões de treinamento, com

classificação conhecida. Assim, o processo é composto de duas fases: treinamento e classificação.

- **Não-supervisionado:** Utilizado nos casos em que não existem informações disponíveis sobre as classes consideradas. O emprego deste modelo força o processo a “aprender” sobre as características das classes através de observações somente sobre os dados disponibilizados para classificação.

Em vários métodos de classificação, normalmente os sub-processos responsáveis por decidir a classificação são as funções de decisão [TG74]. O processo decisório pode ser bem simples, porém podem existir situações em que uma dada característica apresenta informações que normalmente a classificaria para mais de uma classe. Nestes casos, as funções de decisão podem considerar verificações adicionais através de heurísticas específicas para procederem com a decisão.

Um dos mais simples e intuitivos processos para classificação de padrões é a definição de funções de distância [TG74]. Considerando que as características dos elementos podem ser representadas em um espaço Cartesiano através de pontos, torna-se intuitivo classificar esses pontos em classes de similaridade através da proximidade que estes apresentam entre si. Por exemplo, na Figura 2.21 pode-se concluir intuitivamente que x pertence à classe ω_i , pois está mais próximo dos padrões desta classe no espaço.

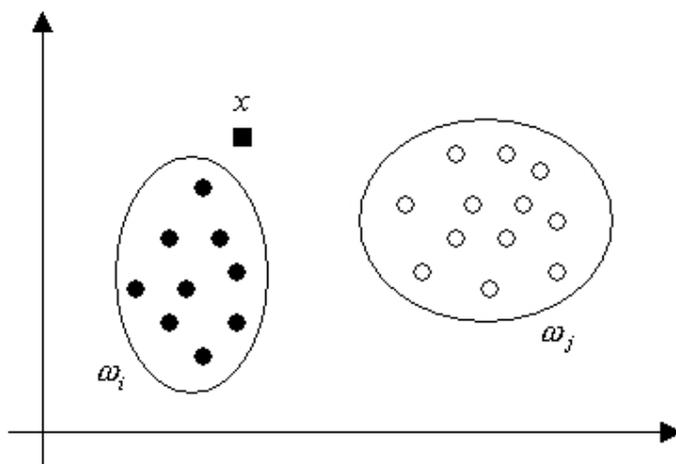


Figura 2.21: Exemplo de classificação de padrões pelo conceito de proximidade. (adaptado de [TG74])

Para realizar tal classificação pode-se encontrar os agrupamentos que definem determinados padrões de dados. Cada agrupamento pode ser representado através de seu centro, que será utilizado para a classificação através do cálculo das distâncias dos pontos no espaço. Porém, existem casos onde a classificação pode não ser intuitiva, ou a distribuição dos dados não apresentar algum padrão conhecido matematicamente.

Um método de classificação supervisionado que tem sido utilizado com bastante frequência em reconhecimento de padrões são as redes neurais artificiais. Este método baseia-se na capacidade de armazenamento e manipulação de informações dos sistemas neurais biológicos [San04]. As redes neurais artificiais são capazes de aprender (modelo supervisionado) as características estatísticas através de dados de treinamento. A qualidade do aprendizado depende diretamente da quantidade e da qualidade dos dados submetidos para treinamento. O reconhecimento de padrões utilizando redes neurais artificiais é considerado um método estatístico [Hay01].

2.7.3. O Classificador K-Means

O objetivo do algoritmo K-Means é classificar um conjunto de dados em um certo número de agrupamentos (K), definido *a priori*, através da análise de suas similaridades. O algoritmo utiliza um método estatístico não-supervisionado para classificação, o qual é uma variação do algoritmo EM (*Expectation-Maximization*) que trabalha geralmente com dados gerados de distribuições Gaussianas. Conforme Matteucci [Mat05], o classificador K-Means é o mais simples algoritmo de aprendizado não-supervisionado para resolver problemas de agrupamento de dados. Weisstein [Wes05] afirma que este classificador é utilizado com razoável frequência por motivo de sua simplicidade de implementação.

Existem diversas áreas que utilizam o classificador K-Means, como por exemplo [Tek04]: aplicações de aprendizagem não-supervisionada, reconhecimento de padrões, análises classificatórias, inteligência artificial, processamento de imagens, visão computacional, entre outras. Teknomo [Tek04] adiciona que, quando o problema envolver vários objetos que possuem vários atributos e o objetivo é classificar esses objetos baseado em seus atributos, então o algoritmo de classificação K-Means pode ser utilizado.

Mashor [Mas98] define que existem duas versões básicas do classificador K-Means: a versão não-adaptativa introduzida por Lloyd [Llo82], também chamada de algoritmo padrão

K-Means; e uma versão adaptativa introduzida por MacQueen [Mac67]. Porém, ressalta que o algoritmo mais utilizado é a versão adaptativa baseada em distância Euclidiana. As diferenças entre as diversas versões e sub-versões do classificador K-Means, encontram-se em detalhes da geração e ajuste dos agrupamentos e no tratamento de dados, podendo ser discretos ou contínuos [Fab94].

De acordo com Tou e Gonzalez [TG74], o algoritmo de K-Means é definido conforme descrito nos passos a seguir:

1. Escolher K centros de agrupamento iniciais $z_1(1), z_2(1), \dots, z_K(1)$. Estes centros são arbitrários e normalmente são escolhidos K pontos aleatórios da base de características, porém existem diversos métodos para seleção dos centros iniciais, descritos após estes passos.
2. Na k -ésima iteração atribui cada ponto $\{x\}$ a um dos K agrupamentos, usando a relação,

$$x \in S_j(k) \text{ se } \|x - z_j(k)\| < \|x - z_i(k)\| \quad (2.35)$$

para todo $i = 1, 2, \dots, K$, $i \neq j$, onde $S_j(k)$ denota o conjunto de pontos que pertencem ao agrupamento de centro $z_j(k)$. Existem diversas formulações para cálculo de distância (descritas após estes passos), porém este trabalho considera a distância Euclidiana d_{pq} entre dois padrões p e q , como:

$$d_{pq} = \|p - q\| \quad (2.36)$$

3. Re-calcular através dos resultados do passo 2 todos os novos centros $z_j(k+1)$, $j = 1, 2, \dots, K$, de tal forma que a soma das distâncias quadradas de todos os pontos pertencentes a $S_j(k)$ em relação ao novo centro seja minimizada. Assim, o novo centro $z_j(k+1)$ é calculado de tal forma que a função objetivo

$$J_j = \sum_{x \in S_j(k)} \|x - z_j(k+1)\|^2, \quad j = 1, 2, \dots, K \quad (2.37)$$

seja minimizada. O novo centro $z_j(k+1)$ o qual minimiza a função objetivo é calculado através da média simples dos pontos pertencentes a $S_j(k)$. Desta forma, os novos centros são calculados por

$$z_j(k+1) = \frac{1}{N_j} \sum_{x \in S_j(k)} x, \quad j = 1, 2, \dots, K \quad (2.38)$$

onde N_j é o número de pontos em $S_j(k)$.

4. O procedimento deve retornar ao passo 2 caso algum centro tenha se movido, caso contrário o algoritmo convergiu e é terminado. Ou seja, a condição de convergência

$$z_j(k+1) = z_j(k), \quad j = 1, 2, \dots, K \quad (2.39)$$

deve ser verdadeira para o término do algoritmo. Uma variação do algoritmo determina um valor mínimo de movimentação ε do novo centro como aceitável para o término do processo. Desta forma, a condição de convergência é definida como:

$$\|z_j(k+1) - z_j(k)\| < \varepsilon, \quad j = 1, 2, \dots, K \quad (2.40)$$

Os resultados do algoritmo podem apresentar diferenças dependendo dos valores iniciais dos centros [Mas98], [Mat05], conforme definido no passo 1 do algoritmo. Matteucci [Mat05] sugere que o algoritmo seja executado diversas vezes para minimizar este problema, porém, este processo pode representar um alto custo de processamento e de performance para alcançar os resultados finais. Existem várias iniciativas para minimizar este problema [DM90], [DM92], [IS86], [KS94] e [XKO93], além do método proposto por este trabalho, descrito no Capítulo 4.

No passo 2 do algoritmo tem-se a utilização de uma função de distância para definir os agrupamentos. Variações do algoritmo podem utilizar diferentes funções de distância. De acordo com Santos [San04], há uma dependência significativa das medidas de distância em problemas de classificação. A escolha das funções de distância irá determinar a forma dos agrupamentos ótimos [Luk05]. Dentre as diversas funções de distância que podem ser empregadas no algoritmo K-Means, encontram-se a Euclidiana, a Euclidiana Quadrática e a Manhattan, por exemplo.

Normalmente a distância Euclidiana é aplicada quando os elementos das classes tendem a se agrupar perto da média, ou quando as classes apresentam comportamento semelhante quanto a forma de distribuição de probabilidades e valores de variância [San04]. Considerando duas amostras x_i e x_j , tem-se para q -dimensões do espaço de característica as formulações das distâncias Euclidiana, Euclidiana Quadrática e de Manhattan apresentadas nas Equações (2.41), (2.42) e (2.43), respectivamente, sendo as fórmulas adaptadas de [BVS02].

$$d_{ij} = \sqrt{\sum_{k=1}^q (x_{ik} - x_{jk})^2} \quad (2.41)$$

$$d_{ij}^2 = \sum_{k=1}^q (x_{ik} - x_{jk})^2 \quad (2.42)$$

$$d_{ij} = \sum_{k=1}^q |x_{ik} - x_{jk}| \quad (2.43)$$

sendo $k = 1, 2, \dots, q$.

Como descrito anteriormente, o algoritmo de K-Means respeita um modelo de classificação não-supervisionado. Porém, isto não significa que não existe um processo de aprendizagem. Como visto nos passos que compõem o algoritmo, cada ponto considerado no espaço de característica é um exemplo de treinamento para o algoritmo, o qual classifica automaticamente o ponto como pertencente a alguma classe através do centro com a menor distância. Em outras palavras, não é necessário definir para o algoritmo quais informações são de cada classe, ou seja, supervisioná-lo. De acordo com Teknomo [Tek04], o processo de aprendizagem depende dos exemplos de treinamento que são disponibilizados ao algoritmo e este processo pode ser:

- **Treinamento Infinito:** Onde cada dado que é submetido ao algoritmo é considerado como um exemplo de treinamento. Desta forma, cada vez que for realizada uma classificação os centros são deslocados para posições mais significativas dos agrupamentos. Este caso reflete a utilização do classificador K-Means.
- **Treinamento Finito:** É realizado um processo de treinamento anterior à classificação. Diversos dados são submetidos ao algoritmo para que os centros sejam calculados. Depois desse processo os centros são fixados. Desta forma, o processo de classificação apenas identifica em qual grupo o novo ponto será atribuído, sem alterar os valores dos centros.

Como qualquer outro algoritmo, o K-Means possui algumas fragilidades, listadas por Teknomo [Tek04], como segue:

- Quando não existe uma grande quantidade de dados, os grupos iniciais determinam os grupos significativamente.
- O número de grupos K deve ser determinado antes do início do algoritmo.
- Caso poucos dados sejam submetidos ao algoritmo a classificação é imprevisível, pois depende da ordem que os dados são alimentados no algoritmo. Ou seja, os mesmos dados podem possuir classificações diferentes em execuções diferentes, dependendo desta ordem.
- Não é possível determinar qual atributo possui maior relevância para a classificação, visto que todos os atributos possuem os mesmos pesos.

Porém, Teknomo [Tek04] ressalta que uma maneira para superar tais fragilidades é usar o algoritmo com uma grande quantidade de dados, o que se enquadra com a utilização do algoritmo por este trabalho.

2.8. Segmentação de Imagens Coloridas

A segmentação de imagens consiste na partição da imagem em regiões de acordo com alguns critérios, a fim de localizar algum objeto (região) de interesse. O processo de segmentação é considerado como crítico no processamento de imagens digitais e de

considerável complexidade [DMS99], [LWZ03], [Fac96]. Deng [DMS99] ainda ressalta que a maior dificuldade do processo de segmentação está na existência de diferentes texturas, tanto na mesma imagem quanto em diferentes imagens.

A segmentação de imagens coloridas pode ser considerada como uma variação da segmentação de imagens em níveis de cinza, porém, recentemente, tem sido mais utilizada pelos seguintes motivos [LWZ03]:

- As imagens coloridas provêm normalmente mais informações do que as imagens em níveis de cinza;
- O poder de processamento dos computadores tem aumentado rapidamente, fazendo com que esses possam executar algoritmos sobre imagens coloridas com um tempo de processamento aceitável.

Lee [LWZ03] propõe uma classificação dos algoritmos de segmentação de imagens em três grandes grupos:

1. **Segmentação baseada em classificação no espaço de cores:** Consiste na aplicação direta de algoritmos de classificação (Seção 2.7.2) sobre os *pixels*, ou sobre características dos *pixels*, da imagem em um determinado modelo de cores. Alguns exemplos são descritos na Seção 3.1.1.
2. **Segmentação baseada em detecção de bordas (ou contornos):** Consiste normalmente em aplicar algum algoritmo de detecção de bordas, como por exemplo, o detector de bordas de Canny [Can86], na imagem analisada. Na sequência é realizada a união das regiões delimitadas pelas bordas que são consideradas como regiões próximas, ou as informações das bordas são submetidas a algum algoritmo de classificação (Seção 2.7.2). Alguns exemplos são descritos na Seção 3.1.2.
3. **Segmentação baseada em extração de regiões (ou áreas):** Inclui algoritmos de crescimento de regiões e de divisão e união de regiões. Normalmente, focam na tentativa de agrupar *pixels* que se encontram em regiões homogêneas em relação às cores e/ou às texturas. Alguns exemplos são descritos na Seção 3.1.3.

Adicionalmente, Deng [DMS99] cita diversas abordagens que podem ser adotadas para realizar o processo de segmentação de imagens coloridas, como por exemplo: modelos

estocásticos [Bel98], [Del97], [PH95], [Wan98], [ZY96]; crescimento de regiões através de morfologia matemática utilizando *watershed* [SPK97], [Fac96]; difusão de energia [MM97]; particionamento de grafos [SM97]; avaliação quantitativa [BCS98].

2.9. Comentários Finais

A fundamentação teórica disposta neste capítulo é de fundamental importância pois descreve as principais informações referentes à documentoscopia e métodos que consideram cores como base de processamento. As informações sobre documentoscopia pelo tratado de perícias criminalísticas mostra o estado atual das análises de documentos questionados, bem como as premissas que são respeitadas por essas análises e, conseqüentemente, por este trabalho. A introdução a cores e o padrão CIE demonstram através de relacionamentos físicos como as cores são representadas e tratadas em um ambiente computacional. A seção sobre equipamentos especializados demonstra quais as ferramentas baseadas na física e na química que são utilizadas atualmente para realizar a discriminação de tintas em documentos questionados. Os modelos de cores e os processos de conversão são relatados a fim de fornecerem informações necessárias ao entendimento do estado da arte e, principalmente, do método proposto. A seção sobre reconhecimento de padrões descreve os conceitos dessa área e seus principais passos, bem como salienta o classificador K-Means, utilizado no método proposto. No capítulo seguinte são abordados alguns trabalhos na área de segmentação de imagens coloridas.

Capítulo 3

3 Estado da Arte em Segmentação de Imagens Coloridas

A solução do problema de separação de tintas em documentos questionados é de interesse de muitas organizações de combate a crimes, principalmente da área forense, como por exemplo, o departamento federal de investigações (FBI) dos Estados Unidos da América [FBI05] e a organização internacional de polícia criminal (Interpol) [Int05]. Estas organizações despendem uma especial atenção para a solução deste problema, gerando uma quantidade considerável de trabalhos a respeito [Fil01].

Conforme descrito no capítulo anterior, as soluções atuais baseiam-se quase que em sua totalidade em análises físico-químicas cromatográficas, como por exemplo [All98], [Nor05] e [TO98]. Uma análise através de segmentação computacional é proposta por este trabalho (Capítulo 4), porém não foram encontradas fontes que utilizam essa técnica aplicada especificamente para separação de tintas. Desta forma, inclui-se neste capítulo trabalhos que envolvem técnicas de segmentação de imagens coloridas, consideradas como base para o desenvolvimento do método proposto, como por exemplo, [LWZ03], [CPM+02], [ZW00] e [DPA00].

Neste capítulo os trabalhos relacionados são descritos e classificados em métodos de segmentação de imagens coloridas que respeitam diferentes abordagens. Assim como um resumo tabelado dos métodos (Seção 3.2) e uma visão crítica do estado da arte (Seção 3.3) são apresentados.

3.1. Segmentação de Imagens Coloridas

Conforme descrito na Seção 2.8, a segmentação de imagens consiste na partição da imagem em regiões de acordo com alguns critérios. Como esta definição demonstra os objetivos do método proposto por este trabalho, o estado da arte relata trabalhos de segmentação de imagens coloridas, respeitando a classificação dos algoritmos proposta por Lee [LWZ03] (Seção 2.8).

3.1.1. Segmentação baseada em Classificadores

Algoritmos de segmentação que utilizam classificadores (Seção 2.7.2) normalmente trabalham com os valores dos *pixels* da imagem, ou sobre características extraídas em relação à disposição desses *pixels*. Normalmente esses algoritmos não consideram fortemente regiões homogêneas da imagem, comparando com algoritmos de extração de regiões (Seção 3.1.3), por exemplo.

Para a segmentação, os métodos podem utilizar vários tipos de modelos de cores (Seção 2.5). Zhang e Wang [ZW00], utilizaram o modelo de cores HSI (Seção 2.5.3) para extrair informações de características relevantes para uma classificação utilizando o algoritmo K-Means (Seção 2.7.3). O processo considera os componentes H (matiz) e I (intensidade), separadamente. Primeiro aplica-se o K-Means no componente I encontrando dois centros e gerando uma função de membro *fuzzy* para cada classe. Depois aplica-se o mesmo processo para o componente H . Após esses processos, escolhe-se a grade do primeiro centro de I e do segundo centro de H , junta-se as duas grades formando um vetor bidimensional de características. E, finalmente aplica-se o classificador K-Means sobre este vetor para obter a imagem final segmentada. O algoritmo foi testado dentro de um sistema de processamento de imagens médicas, onde a segmentação é um passo crítico do processamento e pode apresentar diferentes resultados, dependendo dos reagentes utilizados para aumentar o contraste das regiões. Este método proposto apresenta um melhor resultado em relação ao processamento dos componentes separadamente. Como resultados, são apresentados os processamentos de duas imagens, como exemplo, considera-se a Figura 3.1(a) como imagem original, a Figura 3.1(b) como a extração do componente I da imagem original, a Figura 3.1(c) como a extração do componente H e a Figura 3.1(d) apresenta o resultado da segmentação final, utilizando os

componentes I e H . Ressalta-se que a Figura 3.1(d) foi submetida a alguns pós-processamentos, não detalhados pelos autores.

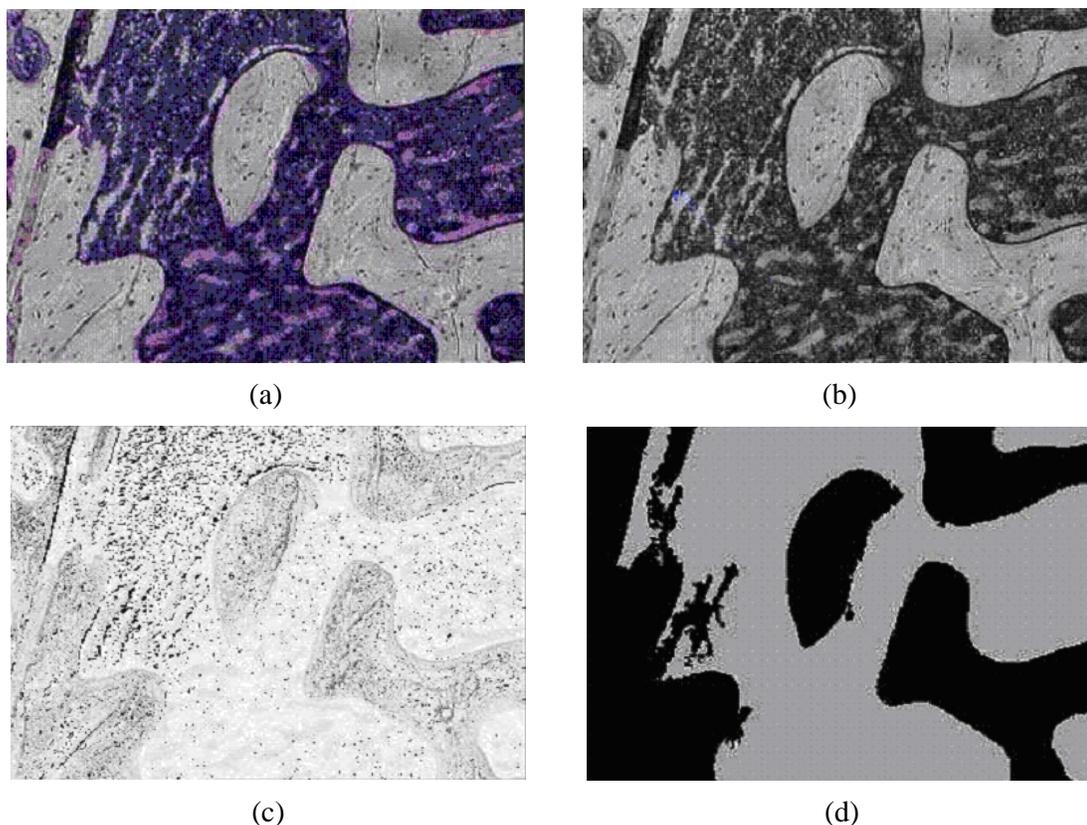


Figura 3.1: Experimentos de Zhang e Wang (adaptado de [ZW00]). (a) Imagem original. (b) Imagem contendo apenas o componente I . (c) Imagem contendo apenas o componente H . (d) Resultado final considerando os componentes I e H .

Chen, Pappas, Mojsilovic e Rogowitz [CPM+02] propõem uma segmentação de imagens considerando cores e texturas separadamente. Conforme a natureza das imagens a serem tratadas, considerar apenas as informações de cores pode ser insuficiente para resultados satisfatórios de segmentação. O processo consiste na segmentação individual dessas duas características e depois na combinação desses resultados. A segmentação por cores é realizada para definir com mais exatidão os limites das regiões da imagem. Para tal, utiliza-se um método baseado no algoritmo ACA (*Adaptive Clustering Algorithm*), que utiliza MRF (*Markov Random Fields*) e o algoritmo K-Means para classificação. O algoritmo ACA realiza a extração de cores dominantes da imagem, ou seja, agrupa as cores que são consideradas mais representativas comparado com a percepção humana de cores simultâneas.

Na segmentação de texturas é utilizado uma estimativa da energia dos coeficientes de uma decomposição *wavelet*. Os experimentos foram realizados em imagens fotográficas com diversas regiões. Foram utilizadas imagens com baixa resolução, sendo algumas degradadas e/ou compactadas. Não existem registros quantitativos publicados sobre a eficácia do método proposto, porém os resultados considerando regiões com fortes diferenças de cores e/ou texturas são considerados satisfatórios. Como exemplo do método proposto tem-se a Figura 3.2(a) como imagem original, a Figura 3.2(b) como resultado da segmentação por cores, a Figura 3.2(c) como resultado da segmentação por texturas e a Figura 3.2(d) como resultado final da segmentação.

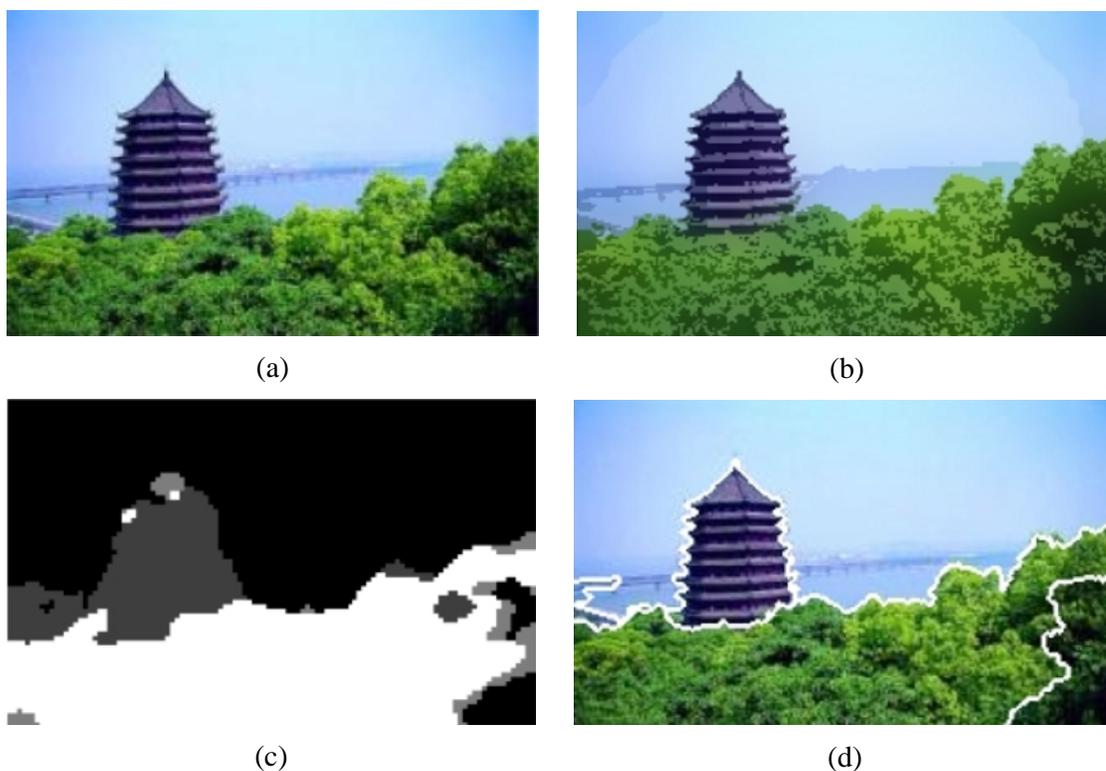


Figura 3.2: Experimentos de Chen, Pappas, Mojsilovic e Rogowitz (adaptado de [CPM+02]). (a) Imagem original. (b) Imagem da segmentação por cores utilizando ACA. (c) Imagem da segmentação por texturas utilizando *wavelet*. (d) Imagem original segmentada.

Outra abordagem considerada apresenta variação dos tipos de características extraídas da imagem para o processo de classificação. Lee, Wang e Zhang [LWZ03] propõem uma extensão do algoritmo EM para GMM (*Gaussian Mixture Model*) chamado K-EM. Este método introduz um passo interno de extração de características (*K-Step*) em um espaço de

características não-linear. As características extraídas para classificação baseiam-se em informações sobre cores e informações espaciais dos *pixels*. Dentre os diversos métodos que podem ser utilizados como KFA (*Kernel Feature Analysis*), na proposta utiliza-se o *Kernel PCA (Principal Component Analysis)*. Um KFA serve para extrair características de uma maneira não-linear. Os experimentos realizados com o método proposto utilizam adicionalmente o *Kernel RBF (Radial Basis Function)* em todas as segmentações. Conforme definido nos objetivos do trabalho, a principal vantagem do método encontra-se na redução do custo computacional em relação aos demais métodos analisados. Diversos parâmetros são solicitados para a realização dos experimentos e os resultados comparam a utilização do método EM padrão e do método K-EM, ambos em GMM. Como exemplo, a Figura 3.3(a) ilustra a imagem original, a Figura 3.3(b) ilustra a segmentação utilizando o método EM básico e a Figura 3.3(c) ilustra o resultado final utilizando o método K-EM proposto.

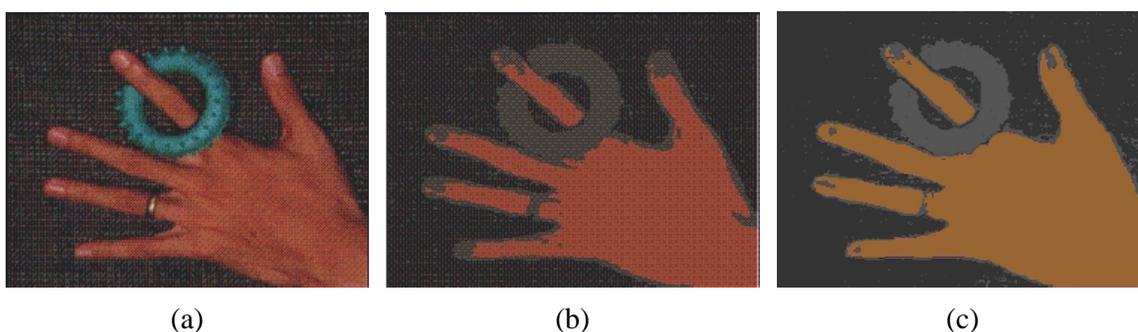


Figura 3.3: Experimentos de Lee, Wang e Zhang (adaptado de [LWZ03]). (a) Imagem original. (b) Resultado da segmentação utilizando o método EM básico. (c) Resultado da segmentação utilizando o método K-EM.

Normalmente os métodos apresentam uma complexidade computacional alta. Muitos dos trabalhos da área baseiam-se na redução desta complexidade. Visando este fim, Lambert e Greco [LG03] propõem um algoritmo de aglomeração de clusters baseado em um critério de validação de clusters derivado de partições *fuzzy*. A classificação inicial é realizada utilizando o algoritmo FCM (*Fuzzy C-Mean*), porém, qualquer outro método de classificação pode ser utilizado neste passo. Basicamente, o processo começa com um número de classes e iterativamente vai unindo essas classes em classes maiores em cada passo. Uma classe válida deve ser compacta e isolada e é definida como uma região de alta densidade a qual é separada por regiões de baixa densidade. O método proposto requer um parâmetro simples e resulta normalmente em um pequeno número de classes com grandes regiões. O método apresenta

como principal vantagem a baixa complexidade e o reduzido tempo de execução. Os experimentos foram realizados utilizando o modelo de cores RGB e a classificação inicial do processo (antes das uniões) é de 16 classes. A Figura 3.4(a) ilustra a imagem original, a Figura 3.4(b) e a Figura 3.4(c) demonstram resultados da segmentação com diferentes valores para o parâmetro α , que compõe a função de decisão de união de classes, quanto menor o valor de α menor será o número de regiões segmentadas.

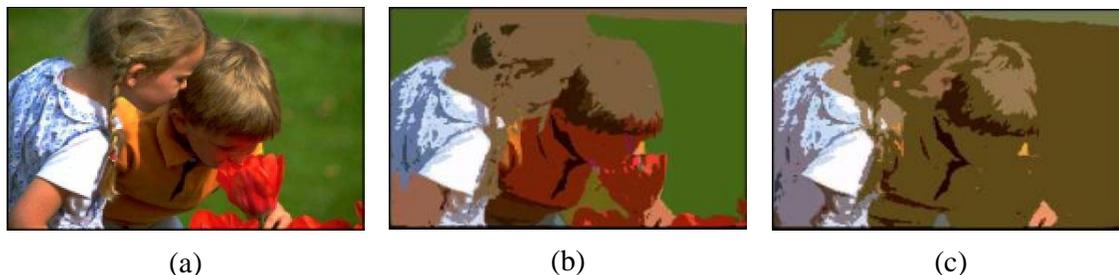


Figura 3.4: Experimentos de Lambert e Greco (adaptado de [LG03]). (a) Imagem Original. (b) Resultado da segmentação ($\alpha = 0.1$). (c) Resultado da segmentação ($\alpha = 0.05$).

Sumengen, Kenney e Manjunath [SKM04] propõem um método variacional, VIS (*Variational Image Segmentation*), que utiliza cores e texturas. Este método utiliza difusão de imagens baseado em um conjunto de *edge vectors*. Vários parâmetros são solicitados a fim de permitir uma especialização do método, conforme o tipo de imagem analisada. Caso seja informado que o método deva utilizar informações de textura, calcula-se as características de textura de Gabor em 3 escalas e 4 orientações. Sobre as características extraídas, um conjunto de *edge vectors* é calculado utilizando diferenças direcionais, onde cada *edge vector* aponta para a borda mais próxima. Com isso, uma *edge function* é calculada sobre os *edge vectors* através da solução da equação de Poisson e o processo é finalizado com a difusão da imagem e a delimitação das regiões. Como exemplo, a Figura 3.5(a) demonstra a imagem original, a Figura 3.5(b) ilustra o resultado dos valores da *edge function*, a Figura 3.5(c) ilustra o resultado da difusão da imagem e a Figura 3.5(d) demonstra o resultado final da segmentação.

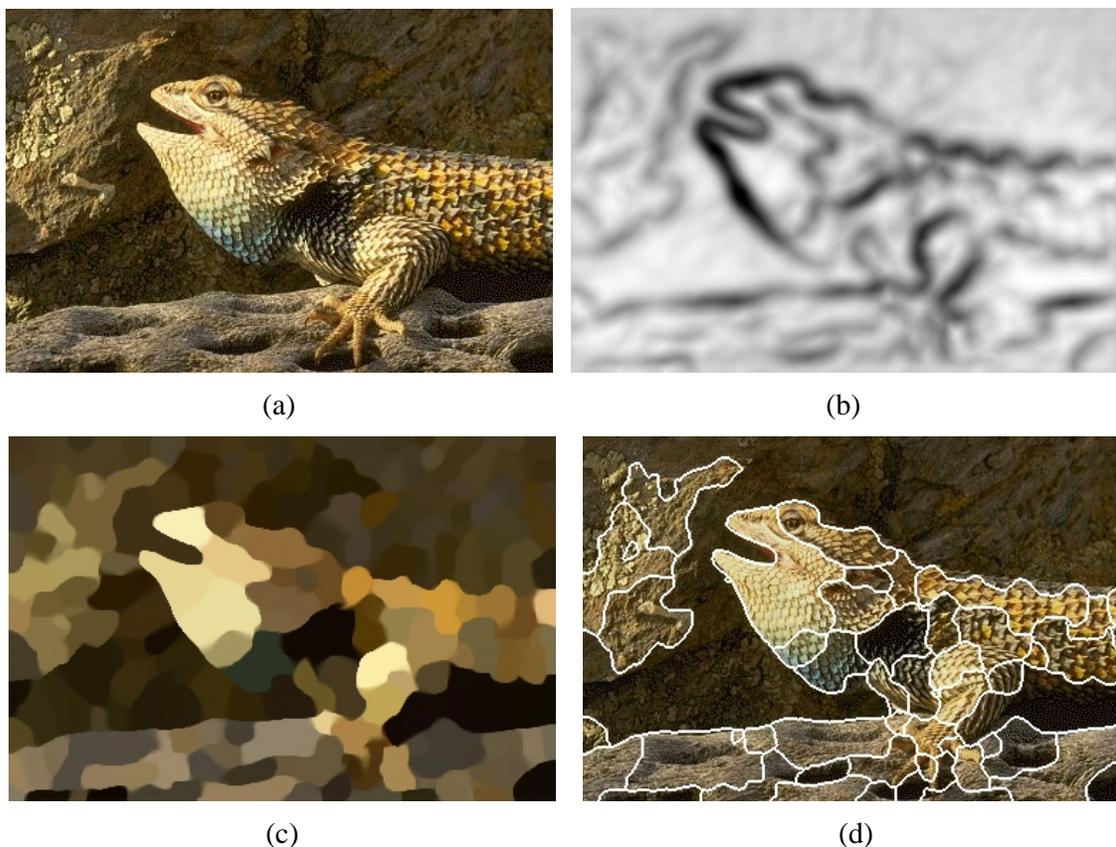


Figura 3.5: Experimentos de Kenney e Manjunath (adaptado de [SKM04]). (a) Imagem original. (b) Imagem dos valores da *edge function*. (c) Imagem resultante do processo de difusão. (d) Imagem resultado da segmentação.

3.1.2. Segmentação baseada em Detecção de Bordas

Algoritmos baseados em detecção de bordas normalmente são utilizados em conjunto com outros algoritmos para o processo de segmentação. As informações de bordas podem auxiliar em processos de segmentação utilizando classificadores e/ou algoritmos de extração de regiões. Estes processos de segmentação apresentam resultados significantes, sendo utilizado em imagens que apresentam regiões bem delimitadas.

Martínez-usó, Pla e García-sevilla [MPG04] propõem um algoritmo de segmentação não supervisionado através de uma abordagem de multi-resolução a qual utiliza informações de cores e de bordas com uma estrutura QT (*Quadtree*) e através de um processo de minimização iterativa de uma função de energia. Como critério para definir o momento final

da segmentação tem-se uma minimização da energia de segmentação, que considera os seguintes fatores: (1) o quanto homogêneas são as regiões; (2) a similaridade entre a imagem segmentada e a imagem original, e; (3) a similaridade entre os contornos obtidos e as descontinuidades da imagem original. Como uma medida discriminante de cor utiliza-se a distância Euclidiana sobre o espaço de cores $L^*a^*b^*$ para calcular a distância entre duas cores, o que possibilita uma análise das cores muito próxima da percepção humana. A união de duas regiões é decidida através de um processo interno que utiliza média, desvio padrão e uma função de densidade probabilística. A detecção de bordas é calculada utilizando o cálculo do gradiente de regiões com fronteiras e um algoritmo de PCA é utilizado para construir a imagem magnitude gradiente da imagem original. Como exemplo, tem-se a Figura 3.6(a) ilustrando a imagem original, a Figura 3.6(b) ilustrando o resultado da detecção de bordas e a Figura 3.6(c) o resultado final da segmentação.

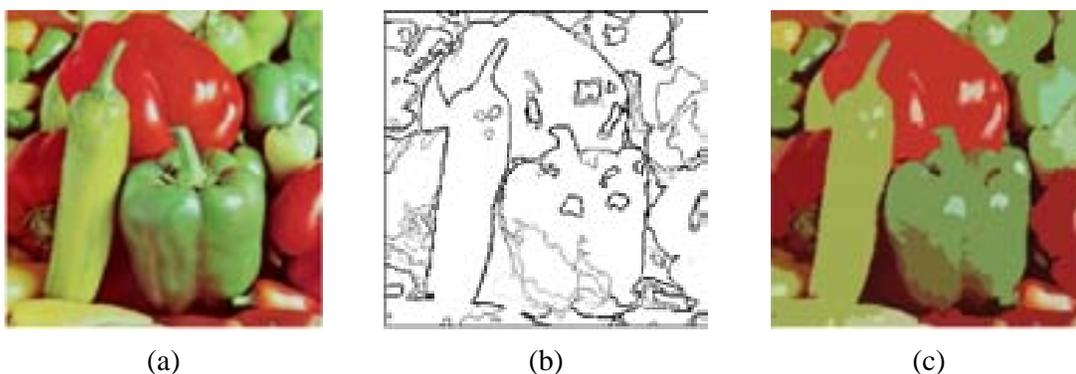


Figura 3.6: Experimentos de Martínez-usó, Pla e García-sevilla (adaptado de [MPG04]). (a) Imagem Original. (b) Resultado da detecção de bordas. (c) Resultado da segmentação.

Ihlow e Seiffert [IS03] utilizam técnicas de segmentação de imagem para detecção de células de cevada transgênicas em imagens coloridas de microscópio. A técnica utilizada é o algoritmo de detecção de bordas de Canny sobre o canal H (matiz) do modelo de cores HSV. São realizadas comparações entre esse método, detecção de bordas no modelo RGB e classificação sobre as cores dos *pixels*. O resultado é que o método de Canny sobre HSV apresenta resultados bem superiores aos demais em relação à extração das células da imagem. Como exemplo, a Figura 3.7(a) demonstra a imagem original de uma célula de cevada com transformações genéticas. A Figura 3.7(b) e a Figura 3.7(c) demonstram os resultados da aplicação do algoritmo de Canny sobre o componente H do modelo de cores HSV, com seus respectivos parâmetros.

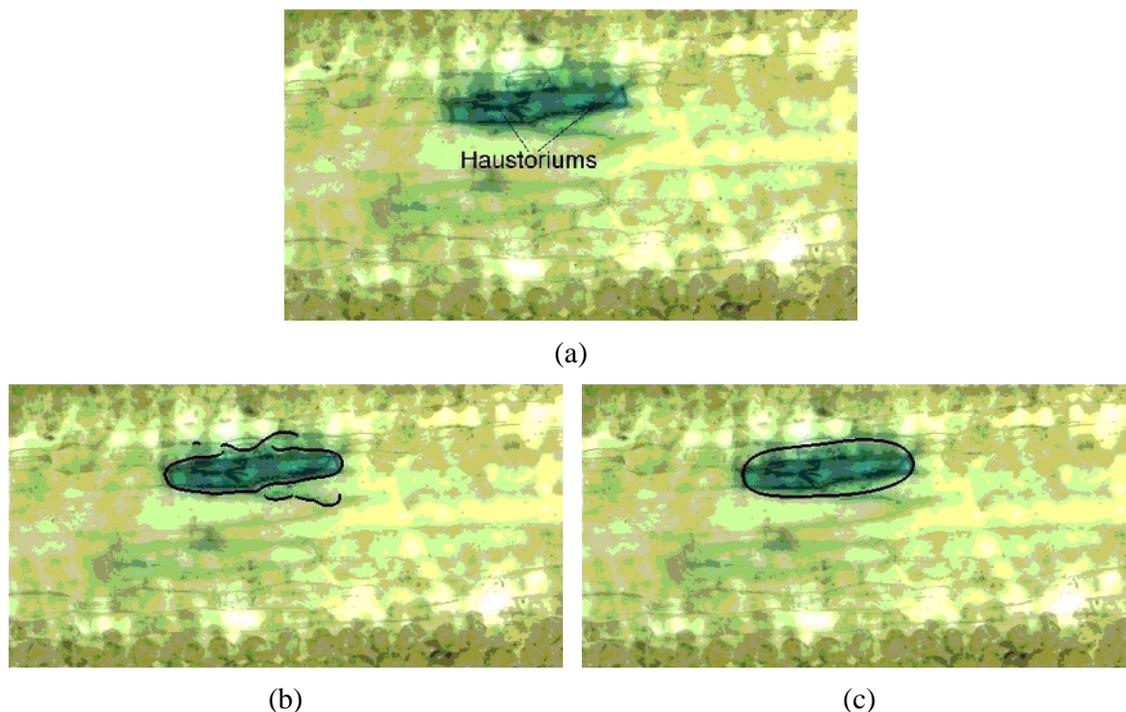


Figura 3.7: Experimentos de Ihlow e Seiffert (adaptado de [IS03]). (a) Imagem original de uma célula de cevada transformada geneticamente. (b) Resultado da detecção de bordas por Canny ($\sigma = 5$, *low threshold* 0.16, *high threshold* 0.4). (c) Resultado da detecção de bordas por Canny ($\sigma = 12$, *low threshold* 0.16, *high threshold* 0.4).

3.1.3. Segmentação baseada em Extração de Regiões

Algoritmos baseados em extração de regiões são normalmente aplicados em imagens que possuem os objetos a serem segmentados em regiões homogêneas. Assim, casos onde existem diferenças bruscas de luminosidade e/ou texturas em uma mesma área do objeto, podem não apresentar resultados satisfatórios.

Dorkó, Paulus e Ahlrichs [DPA00] modificam e compararam dois algoritmos baseados na extração de regiões: o algoritmo CSC (*Color Structure Code*) [RB95] e o algoritmo *split and merge* [DJ93]. Os dois algoritmos são comparados em uma análise de imagem baseada em conhecimento, para exploração de cenas. Antes da aplicação dos algoritmos de segmentação, as imagens são pré-tratadas com o algoritmo de filtro SNN (*Symmetric Nearest Neighbour*). A segmentação CSC é baseada em uma estrutura de dados

própria chamada de estrutura de ilha hexagonal (Figura 3.8). Esta estrutura possui, no nível 0, uma ilha com 7 *pixels*. No nível 1, possui 7 ilhas do nível 0 e assim por diante, até ter uma ilha apenas representando toda a imagem. As ilhas do mesmo nível também compartilham entre si uma ilha (ou *pixel* se for o nível 0). O algoritmo CSC depende fortemente da definição pelo usuário de um parâmetro: *threshold*. Este parâmetro determina a similaridade de dois vetores de cores dependendo de uma distância de cores escolhida e apresenta diferenças significativas no processo de segmentação. Os resultados apresentados baseiam-se na procura de objetos em um escritório e demonstram que tanto o pré-tratamento da imagem de entrada quanto a escolha do parâmetro *threshold* contribuem para que os resultados sejam muito diferenciados. Contudo, conforme objetivo inicial do método, o tempo de processamento é considerado baixo pelos autores, comparado com versões anteriores do método, todavia, comparações com outros métodos não são demonstradas. A Figura 3.9(a) demonstra o único exemplo de imagem de entrada do processo, a Figura 3.9(b) ilustra o resultado utilizando o método *split and merge* [DJ93] e a Figura 3.9(c) demonstra o resultado utilizando o método CSC, porém não foram informadas as condições para obtenção desse resultado.

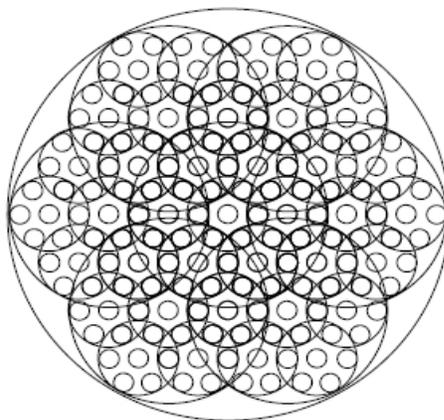


Figura 3.8: Topologia de ilhas hexagonais. (adaptado de [DPA00])

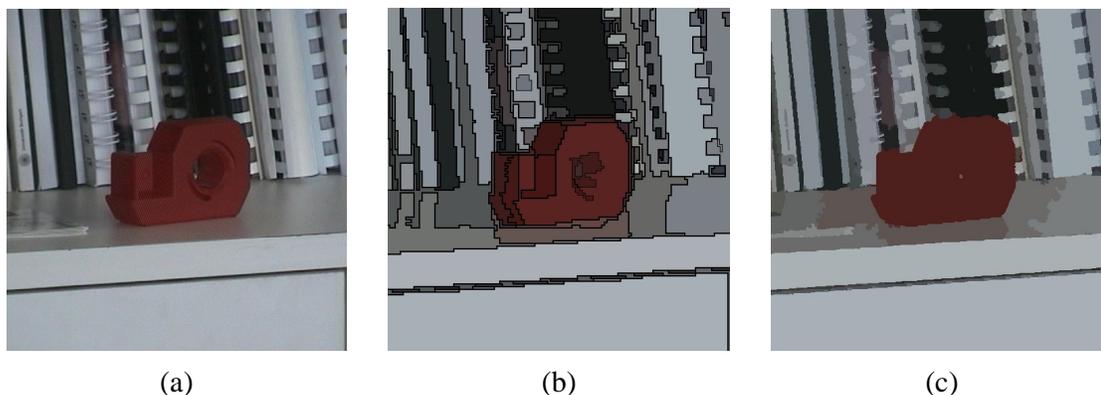


Figura 3.9: Experimentos de Dorkó, Paulus e Ahlrichs (adaptado de [DPA00]). (a) Imagem de Entrada. (b) Imagem resultante da segmentação por *split and merge*. (c) Imagem resultante da segmentação por CSC.

Com o intuito de criação de um processo automático de segmentação, Deng, Manjunath e Shin [DMS99] propõem uma nova abordagem para segmentação de imagens coloridas chamado JSEG. Primeiramente, as cores da imagem são quantizadas em várias classes representativas, que podem ser usadas em diferentes regiões da imagem, conforme [DKM+99]. Então, os *pixels* da imagem são repassados pelos seus correspondentes *labels* de classe, formando assim um *class-map* da imagem. A aplicação de um critério para “boa” segmentação nas janelas locais do *class-map* resulta em uma *J-Image*, no qual altos ou baixos valores correspondem a possíveis regiões de fronteira ou de centros, respectivamente. Um método de crescimento de região é então utilizado para segmentar a imagem baseado em *J-Images* multi-escalares. O processo necessita da definição de 3 parâmetros pelo usuário: (1) o *threshold* para o processo de quantização das cores da imagem; (2) o número de escalas para a segmentação espacial e (3) o *threshold* para a união das regiões. Contudo, mesmo com a necessidade da definição desses parâmetros, foram processadas 2.500 imagens sem alterações dos parâmetros e os resultados foram satisfatórios, conforme [DMS99]. Os resultados apresentados incluem uma variedade de tipos de imagens. Como exemplo, a Figura 3.10(a) demonstra a imagem original, a Figura 3.10(b) é o resultado do processo de quantização com 13 cores, a Figura 3.10(c) demonstra um resultado após a segmentação com escala 3 em 9 regiões e, a Figura 3.10(d) demonstra o resultado final depois da união das regiões em 27 regiões.

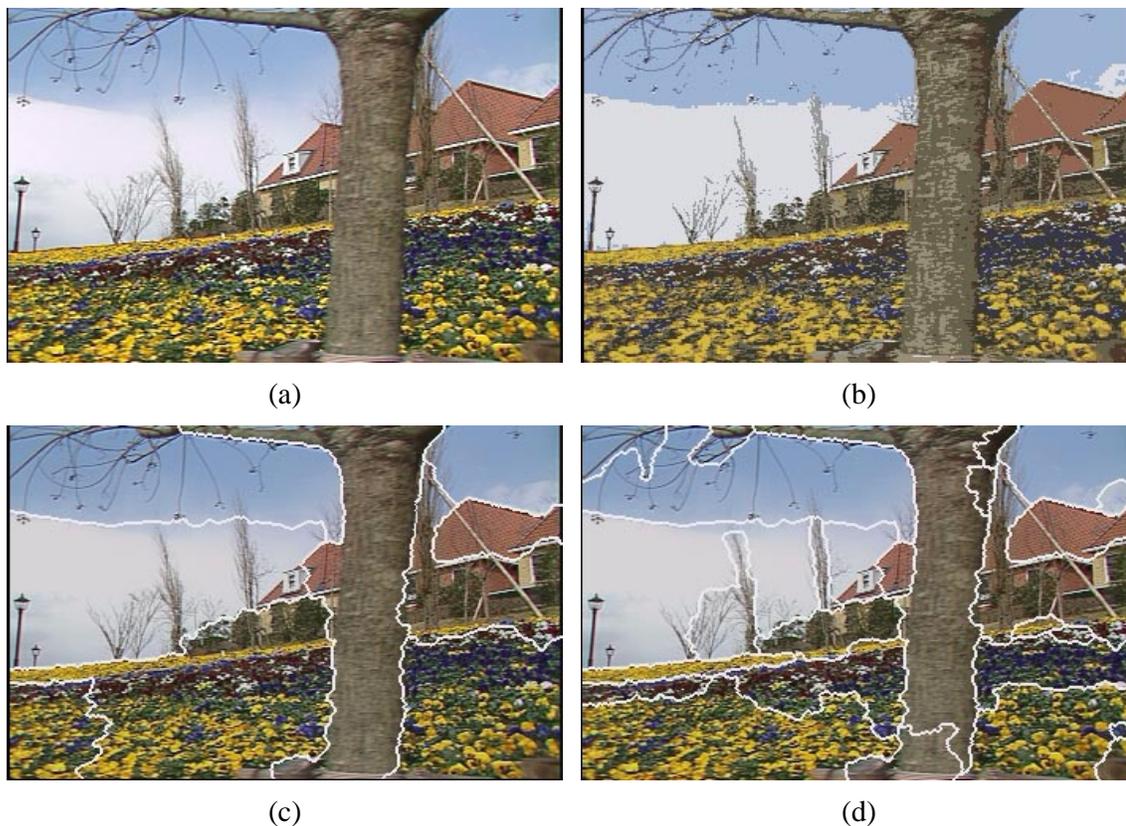


Figura 3.10: Experimentos de Deng, Manjunath e Shin (adaptado de [DMS99]). (a) Imagem original. (b) Resultado do processo de quantização, com 13 cores. (c) Resultado após segmentação com escala 3 em 9 regiões. (d) Resultado final depois da união das regiões em 27 regiões.

3.2. Resumo do Estado da Arte Relevante

A Tabela 3.1 demonstra o resumo das abordagens consideradas como base deste trabalho, enfatizando os métodos utilizados e suas principais características.

Tabela 3.1: Resumo do estado da arte relevante para a dissertação.

Referência	Método(s)	Características
Zhang e Wang [ZW00]	Baseado em Classificadores. Classificador K-Means e MRF.	Este método é baseado no algoritmo K-Means sobre o espaço HSI, considerando os componentes matiz e intensidade, separadamente.
Chen, Pappas, Mojsilovic e Rogowitz [CPM+02]	Baseado em Classificadores. Classificadores K-Means e MRF. Decomposição <i>wavelet</i> discreta (DWT).	Considera cores e texturas separadamente. Segmentação por cores utiliza método ACA e por texturas utiliza DWT.
Lee, Wang e Zhang [LWZ03]	Baseado em Classificadores. Classificador K-EM proposto utilizando <i>Kernel</i> PCA.	Extensão do algoritmo EM para GMM introduzindo um passo interno de extração de características (<i>K-Step</i>) em um espaço de características não-linear.

Referência	Método(s)	Características
Lambert e Greco [LG03]	Baseado em Classificadores. Classificador FCM e partições <i>fuzzy</i> .	Método de aglomeração de clusters baseado em um critério de validação derivado de partições <i>fuzzy</i> .
Sumengen, Kenney e Manjunath [SKM04]	Método Variacional que utiliza <i>edge vectors</i> .	Método variacional VIS que utiliza cores e texturas, realiza difusão da imagem baseado em um conjunto de <i>edge vectors</i> .
Martínez-usó, Pla e García-sevilla [MPG04]	Método variacional que utiliza detecção de bordas por cálculo do gradiente.	Abordagem variacional de segmentação não supervisionada a qual utiliza informações de cores e de bordas com uma estrutura QT e através de um processo de minimização iterativa de uma função de energia.
Ihlow e Seiffert [IS03]	Baseado em Detecção de Bordas.	Utiliza o algoritmo de detecção de bordas de Canny sobre o canal <i>H</i> (matiz) do modelo de cores HSV.
Dorkó, Paulus e Ahlrichs [DPA00]	Baseado em Extração de Regiões.	Modificação dos métodos CSC e <i>split and merge</i> , onde ambos segmentam imagens coloridas em regiões.
Deng, Manjunath e Shin [DMS99]	Baseado em Extração de Regiões.	Método de segmentação totalmente automático de imagens coloridas, chamado JSEG.

3.3. Visão Crítica do Estado da Arte

A visão crítica do estado da arte analisa as fontes que foram utilizadas para o desenvolvimento deste trabalho. Salientando suas vantagens e limitações busca-se refinar as características que podem ser utilizadas no método proposto (Capítulo 4). Entretanto, uma comparação direta do método proposto com as fontes do estado da arte torna-se inviável, pois as bases de dados são diferentes, além de muitas das fontes não disponibilizarem o método completo para execução e quantificação dos resultados. Contudo, os métodos com programas e/ou código fonte disponibilizados [SKM04] e [DMS99] possuem seus resultados comparados no Capítulo 5.

Considerando os métodos computacionais de segmentação de imagens coloridas, desenvolver um método que atue satisfatoriamente em uma grande variedade de situações constitui uma tarefa de alta complexidade. Os métodos analisados, em sua maioria, propõem soluções que podem ser submetidas em diversas situações, porém os resultados nem sempre são satisfatórios para todos os casos.

O método proposto por Zhang e Wang [ZW00] é considerado como forte base para este trabalho, pois não considera tão somente o modelo de cores RGB (Seção 2.5.1). Contudo, considera apenas o modelo HSI, o que dependendo da imagem pode trazer informações insuficientes para análise de tintas. Nas fontes disponíveis do trabalho algumas imagens de

resultados são omitidas. Fato que impede a conclusão de que, mesmo nos exemplos dispostos, o método de união dos componentes gera o melhor resultado de segmentação.

Considerando não somente cores mas também texturas, o método proposto por Chen, Pappas, Mojsilovic e Rogowitz [CPM+02] assume que as regiões necessitam possuir cores e/ou texturas bem diferentes para segmentar. Essa característica pode apresentar resultados insatisfatórios na análise de tintas, pois normalmente neste caso tem-se regiões diferentes onde as tintas possuem cores muito próximas, além de não possuírem uniformidade de textura para cada região que deve ser segmentada, podendo duas regiões diferentes possuírem a mesma textura.

O método proposto por Lee, Wang e Zhang [LWZ03] utiliza o *Kernel PCA* que é eficiente e pode trabalhar com dados complexos, porém apresenta um problema de alto custo computacional quando uma grande quantidade de dados deve ser analisada. O método propõe uma redução neste custo de performance e conclui que obteve resultados satisfatórios para imagens reais, porém não foi descrito o quão satisfatórios estes são. Os resultados dispostos no trabalho retratam que algumas regiões com cores semelhantes são reunidas na mesma região e que o fundo por completo não é classificado na mesma região, conforme ilustrado na Figura 3.3(c). Estes fatores, adicionados da necessidade de definição de diversos parâmetros que dependem das amostras analisadas, fazem com que essa abordagem possa apresentar problemas na análise proposta por este trabalho.

Objetivando uma baixa complexidade computacional, o método proposto por Lambert e Grecu [LG03] necessita apenas de um parâmetro que determina indiretamente a quantidade de classes que o resultado final terá. Tanto a definição desse parâmetro quanto a classificação inicial do método são fortemente correlacionados com o resultado final.

O método VIS proposto por Sumengen, Kenney e Manjunath [SKM04] e o método JSEG proposto por Deng, Manjunath e Shin [DMS99], assumem que cada região da imagem contém um padrão de textura distribuído uniformemente, o que nem sempre acontece com fotos ampliadas de documentos questionados. Porém o método VIS é configurável para trabalhar apenas com cores. Testes comparativos entre o método VIS e o método proposto (Capítulo 4) estão descritos no Capítulo 5 deste documento.

O método proposto por Martínez-usó, Pla e García-sevilla [MPG04] e o método de Ihlow e Seiffert [IS03] apresentam resultados satisfatórios para os testes apresentados, porém

as imagens analisadas apresentam bordas bem definidas, sendo necessário analisar casos onde as imagens não apresentassem bordas bem definidas, para uma comparação com uma possível utilização com documentos questionados.

Os métodos CSC [RB95] e o algoritmo *split and merge* [DJ93] modificados e comparados por Dorkó, Paulus e Ahlrichs [DPA00], possuem uma alta dependência do processo de pré-tratamento e dependendo da cena que está sendo explorada, um pré-tratamento diferente é utilizado. Adicionalmente, o resultado do algoritmo CSC é fortemente dependente do parâmetro *threshold*, que, por sua vez, determina a similaridade de dois vetores de cores dependendo de uma distância de cores. Estas dependências fazem com que os algoritmos atuem em casos específicos, dependendo do pré-tratamento e dos parâmetros.

3.4. Comentários Finais

Os trabalhos apresentados neste capítulo contribuem na análise e escolha de métodos e técnicas para a elaboração do método proposto através de observações sobre as características e os resultados apresentados por estes. Desta forma propõem-se um método de segmentação baseado em classificadores, utilizando o algoritmo não supervisionado K-Means com características provenientes dos valores coloridos dos *pixels* das imagens, transformados em diversos modelos de cores diferentes. No próximo capítulo são descritas as etapas que envolvem o método proposto.

Capítulo 4

4 Método Proposto

Este capítulo descreve o método proposto através da apresentação de todas as etapas para a segmentação de documentos questionados, onde foram utilizadas canetas esferográficas com corante azul. São apresentadas as características da base de dados, bem como o processo de aquisição das imagens e suas configurações.

O diagrama do método proposto (Figura 4.1) apresenta todas as etapas do processo, identificadas de E1 à E5. Os fluxos de dados entre as etapas são identificados pelas letras de A à D e uma descrição detalhada dos fluxos de dados é apresentada nas seções deste capítulo.

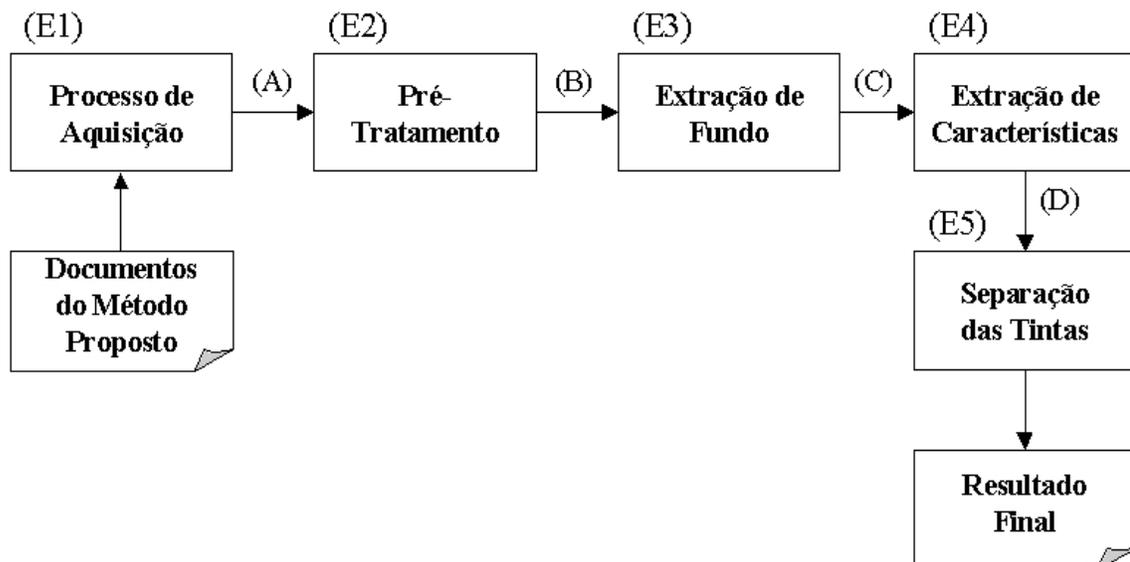


Figura 4.1: Diagrama do método proposto (Nível 1)

O método proposto inicia com a etapa de aquisição de imagens (Seção 4.2) dos documentos questionados que foram selecionados para submissão ao método (Seção 4.1), através de uma câmera digital. Estas imagens (Fluxo A) são enviadas à etapa de pré-tratamento (Seção 4.3), onde as regiões de interesse são alinhadas e recortadas manualmente. Com as imagens contendo apenas as regiões de interesse (Fluxo B), a etapa de extração do fundo (Seção 4.4) separa as regiões de tinta e fundo. A etapa de extração das características (Seção 4.6) recebe as imagens contendo apenas as regiões de tinta (Fluxo C) e o conjunto de características que apresentou melhor resultado de classificação, gerado pelo protocolo de escolha de características (Seção 4.5). Esta etapa converte os valores da imagem, originalmente no modelo de cores RGB, em um vetor de características. A etapa de separação de tintas (Seção 4.7) recebe as imagens contendo apenas as regiões de tinta e o vetor das características extraídas (Fluxo D). Esta etapa segmenta as regiões de cada imagem utilizando o classificador K-Means com o conjunto de características escolhidas.

Desta forma, nota-se que o classificador K-Means foi utilizado no protocolo de escolha de características e nas etapas de extração do fundo e de separação das tintas. Na etapa de extração de fundo, o classificador é utilizado para a segmentação da imagem nas áreas de tinta e de fundo. No protocolo de escolha de características e na etapa de separação de tintas, o classificador é utilizado para a segmentação das duas tintas.

Ressalta-se que o diagrama do método proposto (Figura 4.1) apresenta apenas o nível 1 de análise. Detalhes sobre as etapas e os fluxos de dados entre estas são descritos nas seções desse capítulo.

4.1. Protocolo da Base de Dados

A base de dados contém todos os documentos considerados nos experimentos do método proposto (Capítulo 5). Estes documentos foram criados em laboratório a fim de simular possíveis alterações documentais. Os tipos de canetas e de papel utilizados na criação da base de dados foram escolhidos por seu caráter popular e são descritos detalhadamente no Apêndice A deste documento.

Todos os documentos da base de dados foram criados por um único autor, tanto a escrita original quanto a alteração. Este fato contribui para a redução de interferências quanto às características grafoscópicas (Seção 2.1.1) nos documentos analisados. Além de serem

criados pelo mesmo autor, as alterações documentais foram realizadas com a intenção de falsificação, ou seja, foram tomados cuidados para que as alterações fossem o quanto menos possíveis de serem identificadas através de análises por olho nu ou por uso de lentes de aumento, por exemplo.

O tema de todas as alterações realizadas foi a alteração por emenda (Seção 2.1) do algarismo numérico 3 pelo algarismo numérico 8. Desta forma, o conteúdo original do documento é o algarismo 3 e o conteúdo alterado corresponde à junção das extremidades desse algarismo, semelhante à escrita de um outro algarismo numérico 3, porém espelhado. Como a abordagem da proposta trata da análise dos pigmentos do corante, esse tema é suficiente. Considera-se assim desnecessária a criação de outros tipos de temas de alterações para análise.

A base de dados contém 45 documentos com escritas de canetas que utilizam corante azul. A superfície dos documentos é de papel branco e não apresenta interferências de conteúdos pré-impressos ou de qualquer tipo de ruído, exceto marcas fibrosas que são provenientes do processo de confecção dos papéis. Estes documentos foram digitalizados como imagens no formato TIFF, com dimensão de 1984x1488 e no padrão *True-Color* de 24 BPP. Ou seja, cada *pixel* contém um vetor com três valores de 8 *bits*, onde pode-se representar até 16.777.216 cores diferentes.

A quantidade de documentos da base de dados é considerada suficiente para experimentos iniciais, pois apresenta todas as combinações de 10 canetas, utilizadas em pares. Quando são realizadas alterações de um documento original, normalmente a quantidade de canetas utilizadas são duas: uma do documento original e outra para a alteração.

Os documentos da base de dados foram divididos em dois conjuntos, gerando desta forma dois conjuntos de imagens digitalizadas:

- **Documentos da escolha de características:** geram imagens para o protocolo de escolha de características (Seção 4.5).
- **Documentos do experimento:** geram imagens para os experimentos do método proposto (Capítulo 5).

Os documentos da escolha de características foram selecionados de tal forma a apresentarem as principais características de toda a base. Assim, procura-se aumentar a

probabilidade de que as características escolhidas apresentem melhores resultados, através da submissão ao processo das imagens dos documentos do experimento. Foram selecionados 5 documentos para o processo de escolha de características e 40 para o experimento. A Figura 4.2(a) e a Figura 4.2(b) apresentam exemplos de imagens sem tratamento destes documentos.

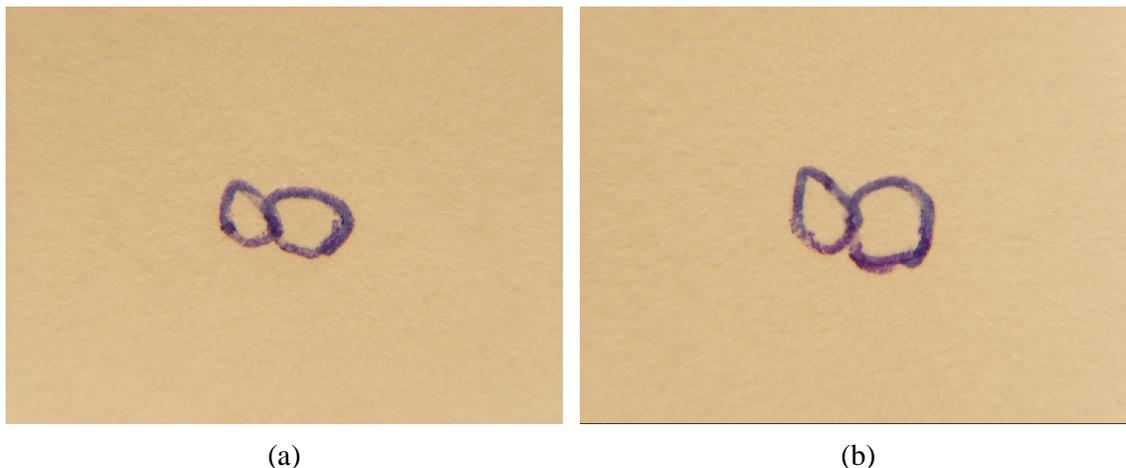


Figura 4.2: Imagem original sem tratamento. (a) Documento selecionado para o processo de escolha de características. (b) Documento para o experimento.

Todas as imagens da base foram digitalizadas através da mesma configuração dos equipamentos. As principais informações referentes a esta configuração estão dispostas na Seção A.3 do Apêndice A.

Normalmente, em documentos forenses são utilizadas canetas de corante azul ou preto, sendo que as canetas de corante azul são as mais comumente utilizadas. Contudo, análises de canetas com outros tipos de corantes e solventes são previstas como trabalhos futuros (Capítulo 6).

4.2. Processo de Aquisição (E1)

O processo de aquisição compreende todas as atividades relacionadas à obtenção de imagens digitais de regiões de interesse de documentos questionados. Esta seção descreve os estudos realizados para a definição do conjunto de equipamentos utilizados neste trabalho.

Para realizar a obtenção das imagens, a proposta deste trabalho (Seção 1.3) prevê a utilização de um conjunto mínimo de equipamentos de baixo custo. Para a definição de um conjunto suficiente de equipamentos para o processo, vários equipamentos foram estudados.

O equipamento básico para a captura de imagens dos documentos é uma câmera fotográfica. As câmeras fotográficas permitem a captura de imagens submetidas à incidência e/ou transferência de diferentes tipos de iluminações, situação que não é permitida com o uso de *scanners*, por exemplo. A câmera utilizada por este trabalho é uma câmera fotográfica digital. Comparada às câmeras *Monoreflex SLR (Single Lens Reflex)* 35mm, câmeras *Monoreflex* médio formato, câmeras de estúdio e câmeras tradicionais, as câmeras digitais apresentam as seguintes vantagens: previsão do resultado fotográfico, isenção do custo de revelação, definição compatível e não necessitam de equipamentos adicionais para representação digital em computadores. Foram diversas as referências consultadas para levantamento de informações relevantes sobre câmeras fotográficas digitais, dentre estas destacam-se *Fried* [Fri03], *Controle Net* [Con03] e *Olympus* [Oly03]. A câmera escolhida para este estudo representa um baixo custo e possuiu sensor padrão CCD (Seção 2.4.1). A especificação detalhada desta encontra-se no Apêndice A deste documento.

Foram realizados diversos testes com a câmera digital para a definição do melhor formato de arquivo, dentre os utilizados pela máquina, para os trabalhos propostos. Os testes resultaram em diversas imagens digitalizadas pela câmera e estão relacionados na Tabela 4.1.

Tabela 4.1: Estudo sobre formatos de arquivos da câmera digital

Seleção	Tamanho	Compressão	Taxa *	Resolução	BPP **	Cores ***	Cores Únicas
SHQ	1.927 Kb	JPG / JFIF	1 / 2.7	1984x1488	24	16,7	228.228
HQ	633 Kb	JPG / JFIF	1 / 8	1984x1488	24	16,7	226.921
SQ1	620 Kb	JPG / JFIF	1 / 6	1600x1200	24	16,7	187.526
SQ2	528 Kb	JPG / JFIF	1 / 4	1280x960	24	16,7	155.493
SQ2	353 Kb	JPG / JFIF	1 / 4	1024x768	24	16,7	124.822
SQ2	146 Kb	JPG / JFIF	1 / 4	640x480	24	16,7	68.154
TIFF	8.786 Kb	Nenhum	1 / 1	1984x1488	24	16,7	226.355

* : Taxa de Compressão.

** : Bits per *pixel*.

*** : Medido em milhões.

Ressalta-se que as informações descritas na Tabela 4.1 foram extraídas de imagens digitalizadas pela mesma câmera digital utilizada nesse trabalho. Todas as imagens

correspondem à mesma cena e foram digitalizadas com a mesma posição da câmera, através do auxílio de um tripé.

Os resultados deste experimento permitiram que fosse definido o formato TIFF (padrão interno de seleção da máquina fotográfica) para a digitalização das imagens que serão utilizadas no trabalho. Esta decisão deve-se ao fato da imagem armazenada através do formato TIFF apresentar as seguintes características:

- Resolução superior à requerida para o estudo;
- Número de cores únicas próximo às maiores quantidades obtidas por outros padrões da mesma máquina (Tabela 4.1);
- Não utiliza método algum de compressão de imagens (Tabela 4.1).

A câmera utilizada neste trabalho possui uma lente teleobjetiva própria com a funcionalidade *zoom* (analógico), porém, adicionalmente a essa lente, torna-se necessário o uso de lentes *close-up* e lentes *macro* para conseguir uma melhor aproximação das regiões a serem analisadas, conforme especificado no Apêndice A deste documento.

O tipo de iluminação ao qual os documentos foram submetidos é a por incidência, que consiste em posicionar a fonte luminosa sobre a amostra para capturar os raios que são refletidos da mesma (Seção 2.4.1). As fontes luminosas são compostas por lâmpadas halógenas com filamento de tungstênio e estas lâmpadas possuem como principal característica a emissão de ondas em uma grande faixa de comprimento, aproximadamente de 300nm à 1.000nm. Tanto as medidas para o posicionamento das fontes luminosas quanto as especificações destas encontram-se no Apêndice A deste documento.

Como equipamentos acessórios, porém não menos importantes, foram estudados óculos especiais para filtragem de radiações ultra-violeta e para atenuação de outros tipos de iluminações. A incidência contínua e por períodos longos de tempo de alguns tipos de luzes na pele e nos olhos, pode causar problemas de saúde, além de dores de cabeça e cansaço visual.

Conforme mencionado anteriormente, o Apêndice A deste documento possui a descrição do “Documento do Processo de Aquisição”. Este documento apresenta as informações técnicas dos equipamentos utilizados para a formação da base de dados, bem

como definições quanto à documentação das configurações para a obtenção das imagens utilizadas.

As imagens ilustradas na Figura 4.2(a) e na Figura 4.2(b) são os resultados (Fluxo A) desta etapa de processo de aquisição do diagrama do método proposto (Figura 4.1). Todas as imagens são digitalizadas na posição horizontal, desta forma respeita-se a região central do foco automático da câmera digital. Estas imagens são submetidas a um pré-tratamento para que possam ser analisadas, como por exemplo: mudança de formato, rotação e recorte. Estes processos são descritos na próxima seção.

4.3. Pré-tratamento (E2)

Na etapa de pré-tratamento cada imagem é tratada para que apresente somente as regiões de interesse para o estudo e para que esteja disposta de maneira a ser processada corretamente por outros métodos de segmentação, utilizados para comparação dos resultados (Capítulo 5). Todos os tratamentos realizados nesta etapa são “manuais”, ou seja, não são propostos métodos e/ou algoritmos computacionais automáticos ou semi-automáticos que realizam tais tratamentos. A característica manual do processo justificasse pela proposta de uma ferramenta semi-automática de segmentação, a qual não depende desta fase de pré-tratamento. Assim, este processo é realizado apenas a fim de padronizar os experimentos e permitir que estes sejam submetidos a diversos métodos de segmentação, os quais são utilizados para comparação de resultados.

Os tratamentos realizados por esta etapa, conforme ilustrado na Figura 4.3, são: Conversão de formato de TIFF para BMP (E2.1); Rotação da imagem (E2.2), e; Recorte da área de interesse (E2.3). O diagrama do método proposto de nível 2 (Figura 4.3) representa uma visão mais detalhada da etapa 2 do diagrama do método proposto de nível 1 (Figura 4.1). Os três tratamentos desta etapa foram realizados com o *software Irfan View* versão 3.85 [Ski05]. Este *software* se enquadra na categoria de *freeware* para uso não-comercial.

O tratamento de conversão do formato TIFF para o formato BMP não apresenta perda de informações. O formato BMP é um formato sem compactação que suporta vários tipos de padrões de cores. O padrão utilizado foi o *True-Color* com 24 BPP, ou seja, cada *pixel* contém um vetor com três valores de 8 *bits* onde pode-se representar até 16.777.216 cores diferentes. A escolha pelo formato BMP deve-se ao fato de ser um formato sem compactação e com

aceitação nas ferramentas utilizadas neste estudo, como por exemplo: Bibliotecas Gráficas de Programação, Utilitários de Tratamento de Imagens, entre outros.

O tratamento de rotação apenas proporciona uma melhor visualização para análise da imagem. Nenhum processamento do método proposto depende da disposição da imagem.

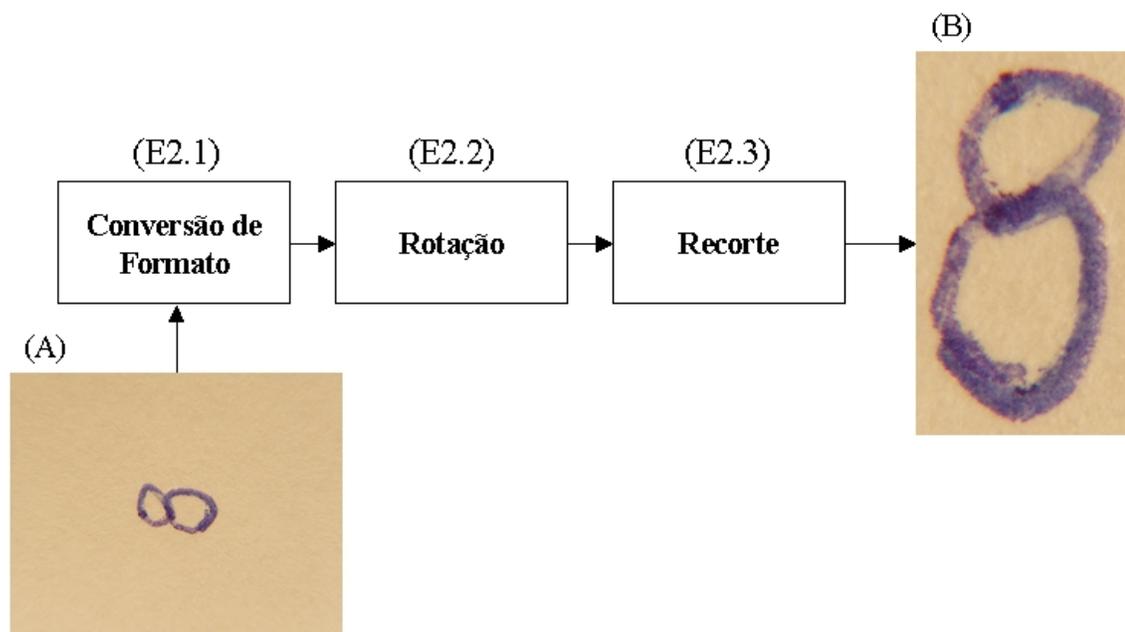


Figura 4.3: Diagrama do método proposto: Etapa E2 (Nível 2)

O tratamento de recorte consiste na seleção apenas da área de interesse da análise e exclusão do restante da imagem. Sua execução apresenta uma redução significativa nas dimensões das imagens. A área de interesse recortada da imagem original representa na média 6,6% dos *pixels* da imagem original, sendo este valor o cálculo da média da redução das imagens da base de dados. Esta proporção apresenta variações dependendo principalmente do tamanho da letra do autor. Fatores de configuração da lente *zoom* da máquina fotográfica também poderiam afetar esta proporção, porém esta configuração é fixa para a obtenção de todas as imagens da base dados (Seção 4.2). A redução das dimensões da imagem proporciona uma redução direta no tempo de processamento da mesma, pois apresenta um número menor de *pixels* para análise. Ressalta-se que apenas são desconsideradas da imagem original as regiões que não são de interesse ao método, conforme ilustrado na comparação entre a Figura 4.2(a) e a Figura 4.4(a), e entre a Figura 4.2(b) e a Figura 4.4(b).

Outra vantagem deste tratamento encontra-se na disposição das imagens para que possam ser analisadas em relação a resultados de outros métodos (Capítulo 5). Um dos métodos disponíveis [SKM04], que foram utilizados por este estudo para a realização da comparação de resultados, realizam uma redução não documentada de escala das imagens para que estas possam ser processadas. Desta forma, imagens com dimensões muito grandes apresentam perda de informações nesse processo de redução de escala.

As imagens resultantes deste pré-tratamento apresentaram uma média de 32.565 cores únicas e dimensão média de 340x559 *pixels*. Ressalta-se que não são alteradas características de escala das imagens submetidas a essa etapa, assim a análise das mesmas não é prejudicada por motivos de distorções e/ou perda de informações em relação à região de escrita. Exemplos dos resultados são ilustrados na Figura 4.4 e na Figura 4.4(b).

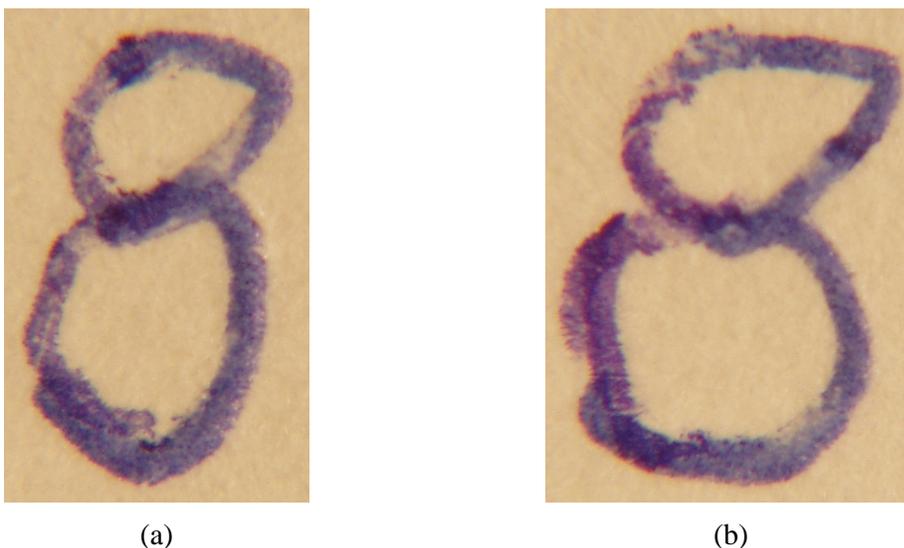


Figura 4.4: Imagem pré-tratada. (a) do conjunto de imagens para escolha de características. (b) do conjunto de imagens para o experimento.

A imagem pré-tratada é enviada (Fluxo B) à etapa de extração de fundo. O procedimento desta etapa é descrito na próxima seção.

4.4. Extração de Fundo (E3)

A etapa de extração de fundo da imagem pré-tratada (Fluxo B) objetiva eliminar as informações dessa imagem que não são relevantes para a análise, ou seja, eliminar o fundo.

Normalmente os documentos apresentam diferenças salientes entre as cores do papel e das tintas das canetas utilizadas, porém existem casos onde porções da região escrita apresentam cores fracas o suficiente para serem confundidas com a cor do papel. Estas situações ocorrem principalmente nos seguintes casos:

- O autor aplica menor pressão vertical da caneta nos momentos de início e/ou término da escrita;
- O autor possui uma característica em toda a sua escrita de aplicar pouca pressão vertical na caneta;
- A caneta apresenta uma falha no processo de captura da massa corante pela esfera, que pode ser ocasionado por sujeira na esfera ou falta de pressão no tubo de condução onde armazena-se a massa corante.

A escolha do método de extração de fundo utilizado por este trabalho baseia-se principalmente nos diferentes resultados apresentados por alguns métodos, em relação à estas situações.

Existem várias tonalidades de corantes de canetas, mesmo considerando apenas às de corante azul e inúmeras variações de pressão exercida pelos autores. Com isso, uma análise direta e individual de algum dos componentes do modelo de cores RGB para a extração do fundo pode apresentar resultados com perdas de informações em relação aos demais componentes. A fim de proporcionar uma melhor extração do fundo, a partir da imagem pré-tratada cria-se uma imagem com informações suficientes para este processo. Esta imagem sintetiza as informações dos componentes significativos da imagem original, ou seja, é gerada a partir de processos de conversão para níveis de cinza.

Conforme a Seção 2.6.5, os métodos de conversão de imagens para níveis de cinza considerados por este estudo são:

1. Atribuição de 0 para o componente S do modelo de cores HSI. O componente S determina o grau no qual a cor não está diluída no branco, ou seja, está relacionado com a diluição do corante no papel.
2. Utilização do componente H do modelo de cores HSI. O componente H representa a própria cor, que no caso da separação do fundo apresenta valores com significativa diferença entre fundo e tinta.

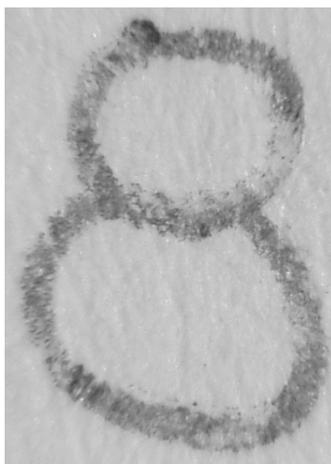
3. Utilização da luminância Y do modelo de cores YUV (padrão PAL) ou do modelo de cores YIQ (padrão NTSC). O componente Y é utilizado nos padrões televisivos pois sua composição visa maximizar o contraste da imagem, desta forma resulta em uma imagem com fundo e tinta bem definidos.
4. Utilização do componente G do modelo RGB. O componente G possui o valor mais significativo na composição do componente Y dos modelos YUV e YIQ.

Observa-se que o método 2 não é um método clássico para conversão de imagens coloridas em níveis de cinza. Porém, seu resultado conforme ilustrado na Figura 4.5(c), armazena informações relevantes ao método de extração de fundo, pois o componente H do modelo de cores HSI sintetiza todas as informações referentes à cor da imagem.

Os métodos 1, 3 e 4 apresentam pequenas, porém, relevantes diferenças em seus resultados finais. A principal diferença encontra-se no nível de contraste da imagem resultante, conforme ilustrado nos exemplos da Figura 4.5(b), da Figura 4.5(d) e da Figura 4.5(e). O contraste é a diferença nas propriedades visuais que fazem com que um objeto seja distinguível de outros objetos ou do fundo de uma imagem. Em outras palavras, o contraste é determinado pela diferença na cor e no brilho da luz refletida ou emitida por um objeto e outros objetos dentro do mesmo campo de visão.



(a)



(b)



(c)

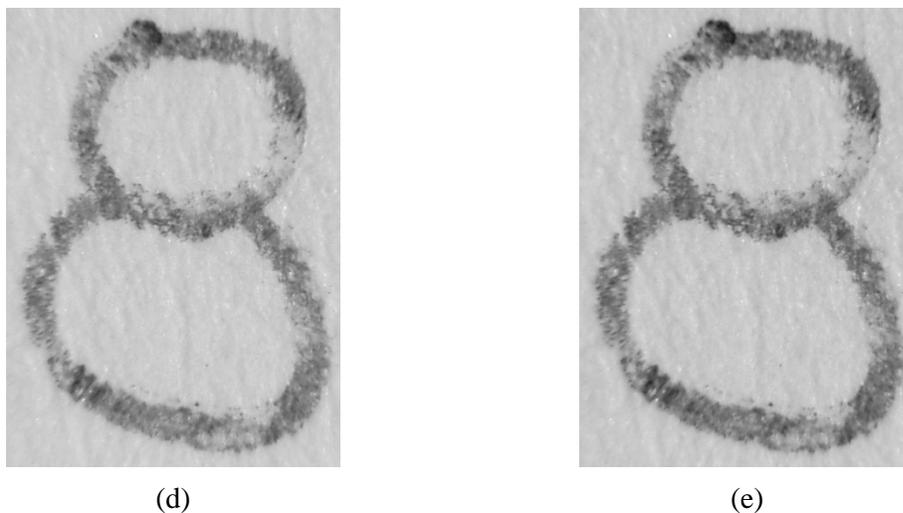


Figura 4.5: Experimentos para conversão em níveis de cinza. (a) Imagem original colorida. (b) Imagem convertida para níveis de cinza atribuindo zero para o componente S do modelo HSI. (c) Imagem convertida para níveis de cinza utilizando o componente H do modelo HSI. (d) Imagem convertida para níveis de cinza utilizando a luminância Y do modelo YUV ou YIQ. (e) Imagem convertida para níveis de cinza utilizando o componente G do modelo RGB.

Como o contraste é uma percepção visual, nota-se visualmente que a Figura 4.5(e) apresenta a melhor definição de contraste, mesmo o resultado sendo muito parecido visualmente com a Figura 4.5(d). Comparando estes dois métodos de conversão, este estudo define o método 3 de cálculo da luminância Y (Figura 4.5(d)), como o método mais adequado para conversão dentre os métodos 1, 3 e 4. Justifica-se tal escolha pois o método de utilização do componente G do modelo RGB produz uma imagem resultante sem informações dos demais componentes, o que prejudica o processo de extração do fundo.

Desta forma, no processo de extração do fundo, considera-se os seguintes métodos para conversão de imagens em níveis de cinza:

- Utilização do componente H do modelo de cores HSI.
- Utilização da luminância Y do modelo de cores YUV (padrão PAL) ou do modelo de cores YIQ (padrão NTSC).

Para o processo de extração do fundo de imagens, normalmente são utilizados algoritmos de limiarização em níveis de cinza ou algoritmos de classificação. Testes com limiarizadores e com classificadores foram realizados para a definição do algoritmo que apresenta melhores resultados, considerando imagens da base de dados. Os limiarizadores

utilizados foram: Anisotropia [Par96], Gradiente SIS (*Simple Image Statistic*) [RW96], Laplaciano de Chehikian [CP95], Entropia de Abutaleb [Abu89], Entropia de Pun [Pun81], Otsu [Ots79] e Otsu-Yan [Yan96]. Os classificadores utilizados foram: Fuzzy C-Means [JBR97] e K-Means (Seção 2.7.3).

Dentre todos os métodos de limiarização, independente do tipo de conversão para níveis de cinza, o método Otsu apresentou os melhores resultados. Todos os resultados foram comparados visualmente, com o conhecimento *a priori* das regiões que deveriam ser limiarizadas.

Os métodos de classificação avaliados apresentaram resultados muito próximos, porém o método K-Means apresentou melhores resultados sobre algumas imagens críticas, onde o corante da tinta estava fraco o suficiente para ser confundido com o papel de fundo. O classificador Fuzzy C-Means, nestes casos, desconsiderou estas regiões como sendo regiões que possuíam corante das tintas. Esses resultados foram obtidos para os dois métodos de conversão para níveis de cinza utilizados.

Através desta pré-análise foram enumerados os seguintes métodos como de melhores resultados (sem relevância de ordem):

1. Limiarizador Otsu sobre o componente *Y* do modelo de cores YUV ou YIQ;
2. Limiarizador Otsu sobre o componente *H* do modelo de cores HSI;
3. Classificador K-Means sobre o componente *Y* do modelo de cores YUV ou YIQ;
4. Classificador K-Means sobre o componente *H* do modelo de cores HSI.

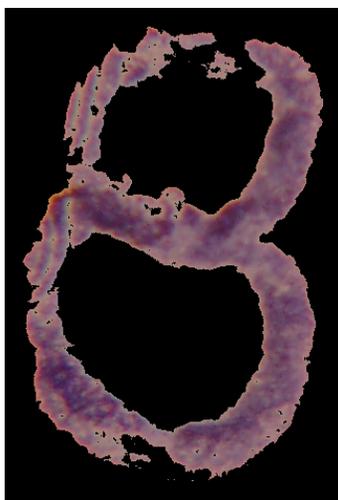
Para os métodos que utilizaram o classificador K-Means, foram selecionados os seguintes parâmetros:

- **Número de características:** Apenas a intensidade do nível de cinza dos *pixels* (1 característica).
- **Número de classes:** As classes da tinta e do fundo (2 classes).
- **Número de iterações:** Não foi definido limites de iterações, estas findam quando o critério de convergência é satisfeito.
- **Critério de convergência:** Quando não há mais movimentação alguma dos centros, ou seja, critério 10^{-3} .

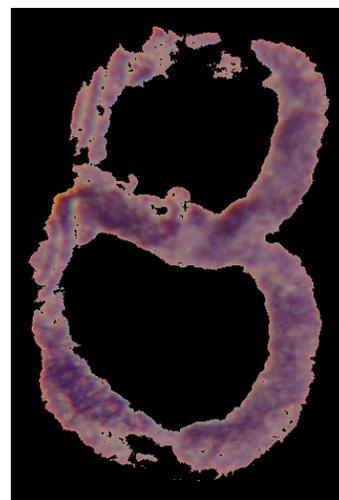
Considerando a análise visual dos resultados, os métodos 1, 2 e 3 apresentaram extrações de fundo semelhantes às esperadas em todas as imagens submetidas à avaliação. Fato que não ocorreu com o método 4 em todas as imagens analisadas. Os métodos 1, 2 e 3 poderiam ser utilizados sem apresentarem prejuízos para o método proposto. Porém, em uma análise com imagens críticas de segmentação, onde existem regiões de tinta que apresentam coloração muito próxima ao fundo da imagem, o método 3 apresentou uma maior constância nos resultados. Esta constância foi observada no que diz respeito a pequenos detalhes da imagem, que foram ignorados pelos demais métodos. Este fato foi decisivo para a escolha do método 3 (Classificador K-Means sobre o componente Y do modelo de cores YUV ou YIQ) para aplicação no método proposto. Como exemplo, a Figura 4.6(a) demonstra uma imagem que é considerada crítica para extração de fundo. Resultados da aplicação dos quatro métodos em relação a esse exemplo são ilustrados da Figura 4.6(b) à Figura 4.6(e), onde pode-se notar que os resultados dos métodos 1, 2 e 3 são muito próximos.



(a)



(b)



(c)

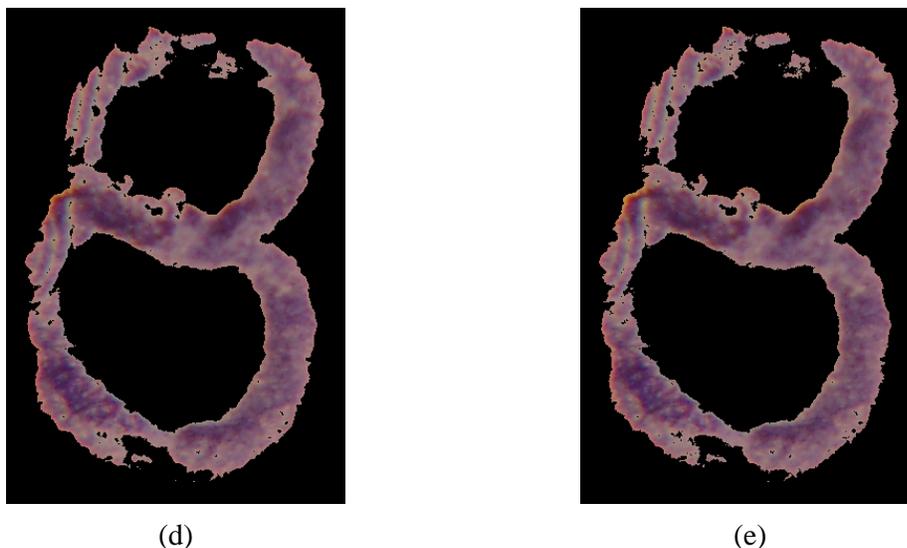


Figura 4.6: Experimentos para extração de fundo. (a) Imagem pré-tratada. (b) Resultado do limiarizador Otsu sobre o componente Y do modelo de cores YUV ou YIQ. (c) Resultado do limiarizador Otsu sobre o componente H do modelo de cores HSI. (d) Resultado do classificador K-Means sobre o componente Y do modelo de cores YUV ou YIQ. (e) Resultado do classificador K-Means sobre o componente H do modelo de cores HSI.

Outros algoritmos de classificação poderiam ter sido escolhidos para serem analisados no processo de extração de fundo. Porém, testes realizados com os classificadores Fuzzy C-Means e K-Means demonstraram que seus resultados foram satisfatórios para o processo. Esta constatação unida com a simplicidade de implementação dos métodos apresenta-se como suficiente para a escolha de apenas esses dois métodos para estudos.

Definido o método para o processo de separação do fundo, tem-se o detalhamento desta etapa ilustrado na Figura 4.7.

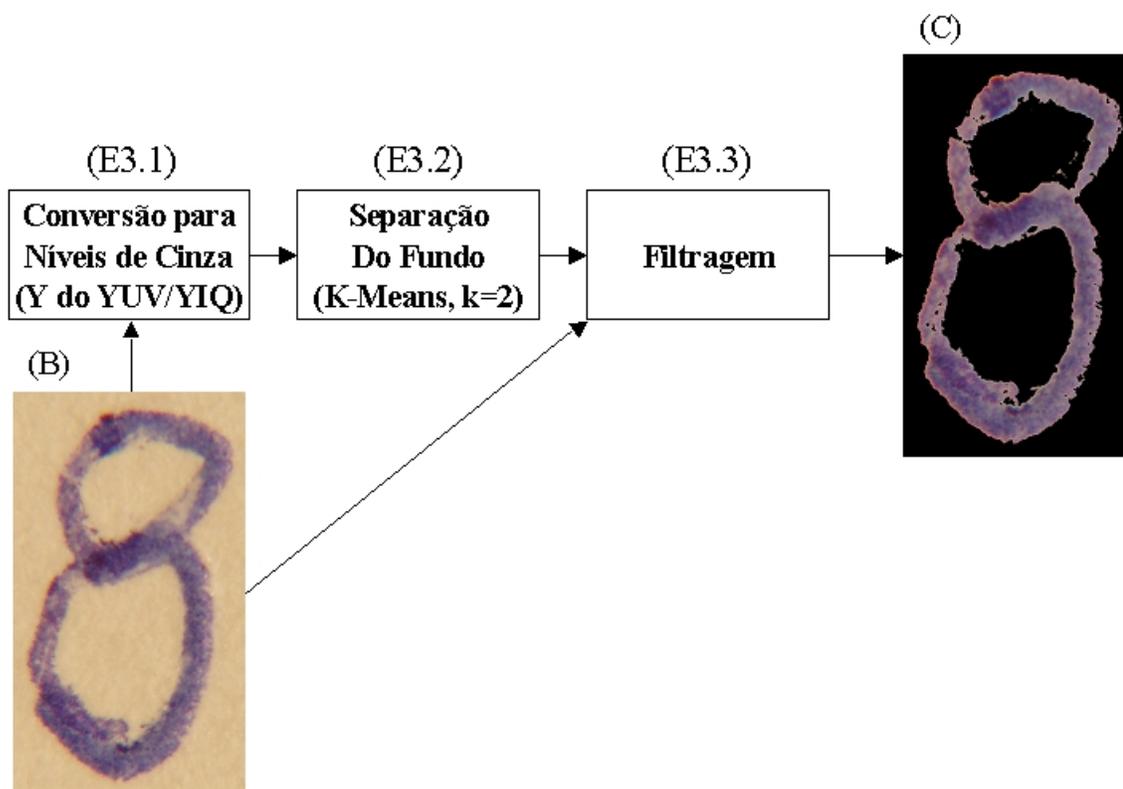


Figura 4.7: Diagrama do método proposto: Etapa E3 (Nível 2)

O processo de conversão para níveis de cinza (E3.1) utiliza o componente Y do modelo de cores YUV ou YIQ, conforme descrito anteriormente.

O processo de separação do fundo (E3.2) utiliza o classificador K-Means conforme justificado anteriormente. A descrição do processo de classificação encontra-se na Seção 2.7.2 e a descrição do classificador K-Means encontra-se na Seção 2.7.3. A imagem em níveis de cinza é submetida ao classificador utilizando como característica apenas a intensidade do nível de cinza dos *pixels* da imagem, normalizados no intervalo $[0,1]$. Desta forma o K-Means considera seu espaço de características como um universo unidimensional. Como a intenção é separar apenas a região de fundo da região onde incidiu tinta, a quantidade de classes configurada como parâmetro para o classificador K-Means é de duas classes ($K = 2$).

O classificador K-Means possui uma dependência quanto ao método que atribui valores iniciais aos seus centros e existem vários métodos propostos para essa tarefa (Seção 2.7.3). Foram considerados para comparação de resultados dois métodos: (1) Inicialização

aleatória dos centros iniciais; (2) Inicialização através da divisão dos valores nos eixos do espaço de características.

O método (1) utiliza um gerador de números aleatórios para definir as coordenadas iniciais dos centros em relação a todos os seus eixos (dimensões do espaço de características). Existem momentos em que pode-se gerar coordenadas iguais para dois centros e nesses casos o processo repete-se a fim de gerar outros valores.

O método (2) é proposto por este estudo e realiza uma divisão de valores nos eixos do espaço de características. Os valores dos centros iniciais são dispostos nos limites da divisão dos valores contidos no espaço de características. Considerando apenas um eixo (Figura 4.8) o procedimento se repete para os demais.

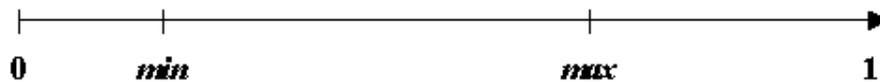


Figura 4.8: Exemplo de um eixo do espaço de características delimitado pelo menor e pelo maior valor de características no eixo

Considerando a formulação da Seção 2.7.3, tem-se os K centros de agrupamentos iniciais $z_1(1), z_2(1), \dots, z_K(1)$. Considere min e max como o menor e o maior valor de característica respectivamente, em um eixo do espaço de características (Figura 4.8). Desta forma, tem-se a definição dos centros iniciais como os limites internos da divisão do intervalo $[min, max]$ em $K+1$ partes iguais, conforme Equação (4.1).

$$z_i(1) = \left(\frac{max - min}{K + 1} \right) i + min \quad (4.1)$$

para todo $i = 1, 2, \dots, K$. A Figura 4.9 demonstra um exemplo da localização dos centros iniciais $z_1(1)$ e $z_2(1)$, considerando apenas o uso de 2 classes em um espaço unidimensional.

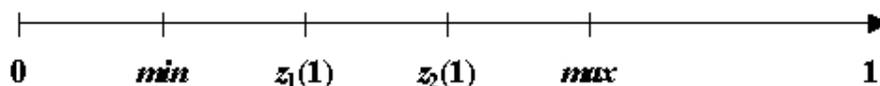


Figura 4.9: Exemplo de um eixo do espaço de características delimitado pelos valores iniciais dos centros $z_1(1)$ e $z_2(1)$

Os dois métodos de inicialização de centros foram testados com 12 imagens selecionadas da base de dados. Os resultados dos testes foram quantificados considerando uma classificação para 2 classes, com valores da característica respeitando o intervalo $[0,255]$ em um espaço unidimensional. As informações consideradas para análise são as coordenadas dos dois centros finais do processo de classificação e a média destes valores, que representa o limite de separação das classes (*threshold*). Desta forma busca-se quantificar a influência dos centros iniciais na classificação final.

O método (1) não apresentou resultados confiáveis para análise comparativa, sendo este executado uma única vez para cada imagem. Dependendo do momento da execução, os resultados finais da classificação apresentaram diferenças com o mesmo conjunto de dados. A Tabela 4.2 apresenta, como exemplo, os resultados finais de 10 execuções do algoritmo K-Means com inicialização aleatória dos centros, sobre uma imagem selecionada ao acaso da base de dados. Nota-se que os resultados não são estáveis dependendo do momento da execução, calculando um *threshold* que varia de 170 à 172.

Tabela 4.2: Resultados de 10 execuções do classificador K-Means com inicialização aleatória de centros sobre uma imagem selecionada da base de dados

Execução	Centro 1	Centro 2	Threshold
01	229	110	170
02	229	110	170
03	230	111	171
04	230	111	171
05	230	111	171
06	231	112	172
07	230	111	171
08	229	110	170
09	230	111	171
10	231	112	172

A Tabela 4.2 demonstra a instabilidade dos resultados finais do método (1) sendo os centros iniciados com valores gerados aleatoriamente. Este fato é suficiente para a não utilização do método (1) neste estudo. Contudo, a fim de comparar os resultados dos dois métodos, para o método (1) foram realizadas 10 execuções sobre cada imagem. Destas execuções foram considerados os valores que apresentaram maior repetição nos resultados finais de classificação dos testes. A Tabela 4.3 demonstra os resultados aplicando os métodos sobre as imagens selecionadas da base de dados.

Tabela 4.3: Resultados da aplicação dos métodos de inicialização dos centros do classificador K-Means sobre as imagens selecionadas da base de dados

Imagem	Método	Centro 1	Centro 2	Threshold
01	(1) Aleatório	97	133	115
	(2) Média	97	133	115
02	(1) Aleatório	111	230	171
	(2) Média	110	229	170
03	(1) Aleatório	108	163	136
	(2) Média	107	162	135
04	(1) Aleatório	77	198	138
	(2) Média	77	198	138
05	(1) Aleatório	9	133	71
	(2) Média	9	133	71
06	(1) Aleatório	31	166	99
	(2) Média	31	167	99
07	(1) Aleatório	16	186	101
	(2) Média	16	186	101
08	(1) Aleatório	130	191	161
	(2) Média	130	191	161
09	(1) Aleatório	24	222	123
	(2) Média	24	222	123
10	(1) Aleatório	5	175	90
	(2) Média	5	175	90
11	(1) Aleatório	23	206	115
	(2) Média	23	206	115
12	(1) Aleatório	4	173	89
	(2) Média	4	173	89

Os resultados dos dois métodos (Tabela 4.3) apresentam algumas situações de variação de *threshold* e nas demais situações os resultados são idênticos. As variações apresentadas são de uma cor no *threshold*, ou seja, mesmo com a execução de 10 vezes do classificador para cada imagem, o método (1) apresenta variações de resultados em relação ao método (2).

O método (2) apresenta resultados estáveis e próximos ao método (1), sendo este executado 10 vezes (Tabela 4.3). Desta forma, considerando esta estabilidade, este estudo utiliza o método (2), de inicialização através da divisão dos valores nos eixos do espaço de características, para definir os valores iniciais dos centros do classificador K-Means.

O resultado deste processo de separação do fundo (E3.2) é uma imagem em níveis de cinza contendo apenas a região que contém a incidência de tinta, com seu fundo na cor preta (Figura 4.7). Contudo, o resultado final da etapa (E3) deve ser uma imagem contendo esta mesma região, porém com as cores originais da imagem. Desta forma, o processo de Filtragem (E3.3) utiliza a imagem pré-tratada (Fluxo B) e a imagem das tintas em nível de

cinza para gerar uma nova imagem com o resultado final colorido. O processo consiste em verificar o valor de cada *pixel* da imagem em níveis de cinza sem o fundo, caso o valor do *pixel* seja superior a 0 (região de tinta) então este *pixel* na imagem resultado recebe o mesmo valor do *pixel* da imagem pré-tratada (Fluxo B).

O processo de filtragem (E3.3) resulta em uma imagem colorida com seu fundo extraído (Fluxo C), conforme exemplificado na Figura 4.6(d) e na Figura 4.10(a). Esta imagem será utilizada na etapa de extração de características (Seção 4.6), na etapa de separação das tintas (Seção 4.7) e no protocolo de escolha de características, descrito na próxima seção.

4.5. Protocolo de Escolha de Características

O protocolo de escolha de características possui o objetivo de definir qual o melhor conjunto de características para serem utilizadas na etapa de extração de características (Seção 4.6). Este conjunto é definido através da combinação de características que apresentarem resultado mais próximo do ideal, definido através de imagens de prova.

As imagens utilizadas para a escolha de características foram selecionadas sendo considerados documentos representativos da base de dados (Seção 4.1).

O protocolo quantifica os conjuntos de características através da submissão das imagens a um processo exaustivo de classificações, a fim de definir as melhores características. Desta forma, as imagens devem ser submetidas inicialmente aos processos de aquisição, pré-tratamento e extração de fundo, definidos neste capítulo.

O protocolo de escolha de características recebe imagens coloridas com seus fundos extraídos. Estas são classificadas utilizando o algoritmo K-Means (Seção 2.7.3) através do método de inicialização aleatória dos centros iniciais, proposto por este trabalho. O processo de classificação utiliza todas as combinações dos componentes dos modelos de cores RGB, HSI e CMYK (Seção 2.5). Os modelos RGB e CMYK apresentam forte acoplamento entre seus componentes, além de representarem as cores primárias aditivas e subtrativas respectivamente. O modelo de cores HSI possui uma representação desacoplada de seus componentes, representando a matiz, a saturação e a intensidade independentes. Desta forma, busca-se a melhor distinção das classes através do teste de características que apresentam

diferenças quanto à representação de seus valores e quanto aos relacionamentos que essas possuem entre si.

Considerando a quantidade de combinações possíveis de serem realizadas com os 10 componentes, cada imagem é submetida 1.023 vezes ao classificador K-Means, que gera 2.046 imagens de resultado, pois a quantidade de classes é 2. Como foram selecionados 5 documentos para a base de escolha de características (Seção 4.1), este protocolo resulta na criação de 10.230 imagens.

Desta forma, o processo de classificação utiliza os seguintes parâmetros:

- **Número de características:** Todas as combinações dos componentes dos modelos de cores RGB, HSI e CMYK, ou seja, dependendo da execução do processo este terá de 2 à 10 características.
- **Número de classes:** As classes da tinta original e da tinta de alteração (2 classes).
- **Número de iterações:** Não foi definido limites de iterações e estas findam quando o critério de convergência é satisfeito.
- **Critério de convergência:** Quando não há mais movimentação alguma dos centros, ou seja, critério 10^{-3} .

O modelo RGB é utilizado no protocolo por ser utilizado pelo equipamento de digitalização e por ser um modelo padrão base para representação de imagens. O modelo HSI é utilizado pois seus componentes não são acoplados e seus valores representam informações que não são compreendidas no modelo de cores RGB. Por fim, o modelo de cores CMYK, mesmo representando informações complementares em relação ao modelo de cores RGB, é utilizado por permitir um agrupamento diferenciado das informações no espaço de características, comparado aos valores do modelo de cores RGB.

Como o padrão para representação de cores de todas as imagens é o modelo RGB, a necessidade de utilização de componentes de um outro modelo, ocasiona a conversão entre modelos a partir do RGB (Seção 2.6). Os resultados destas conversões são normalizados para o intervalo [0,255], a fim de não favorecer alguma característica no processo de classificação.

Como o objetivo do protocolo é definir um conjunto de características que melhor represente a separação das tintas, um processo de quantificação dos resultados do processo de classificação é proposto. A fim de definir quais são os resultados esperados, criou-se

manualmente para cada imagem duas outras imagens de prova, contendo as duas áreas que devem ser classificadas. Como exemplo, a Figura 4.10(a) ilustra uma imagem resultante do processo de extração do fundo. A Figura 4.10(b) e a Figura 4.10(c) ilustram as duas imagens de prova criadas para esta imagem.

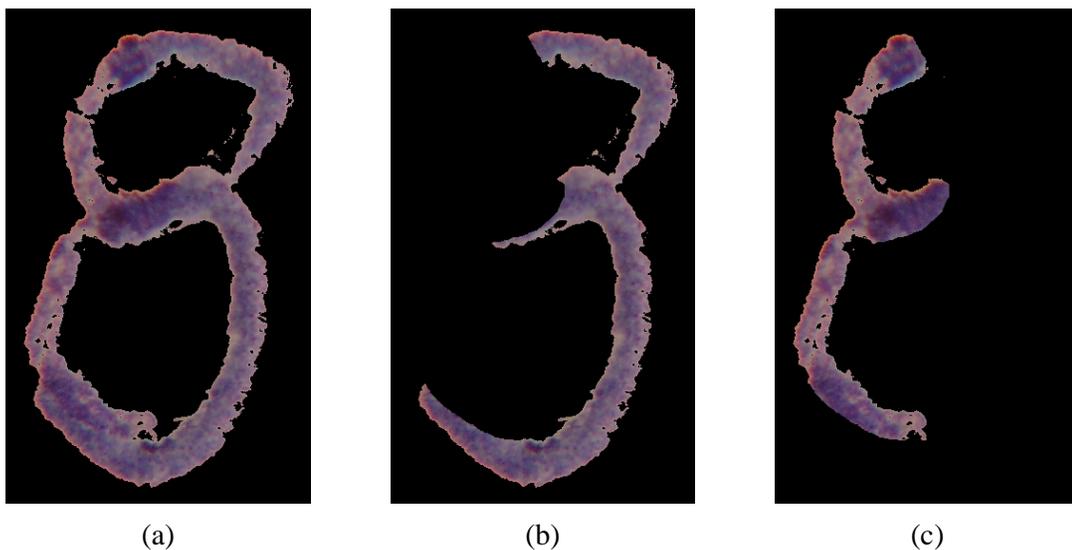


Figura 4.10: Imagens de prova. (a) Imagem resultante da etapa de extração de fundo. (b) Primeira imagem de prova. (c) Segunda imagem de prova.

As duas imagens de prova (Figura 4.10(b) e Figura 4.10(c)) representam o resultado ideal para o processo de classificação. Nota-se que existem regiões na imagem original (Figura 4.10(a)) onde há incidência das duas canetas utilizadas, onde estas se sobrepõem. Nestes casos, as imagens de prova são criadas dividindo a região entre as duas provas, ou a região é dividida e cada parte é atribuída à imagem que representa a tinta onde esta região mais se assemelha. As decisões envolvendo a criação de imagens de prova são todas tomadas a partir de conhecimentos *a priori* sobre a confecção dos documentos com a tinta original e sobre a alteração realizada com outra tinta.

O processo de quantificação dos resultados é realizado através da comparação entre as 2 imagens resultantes da classificação e as 2 imagens de prova geradas manualmente. Considerando todos os valores de *pixels* das imagens, os seguintes valores são calculados:

- **Positivos:** Percentual de *pixels* da imagem resultante da classificação que existem na respectiva imagem de prova.

- **Falsos Positivos:** Percentual de *pixels* da imagem resultante da classificação que não existem na respectiva imagem de prova.

Para cada imagem submetida ao processo calcula-se os percentuais de acertos e de erros. O percentual de acertos é a representação direta do percentual positivo. O percentual de erros é a representação direta do percentual falso positivo.

Como cada imagem contém duas imagens resultantes da classificação e duas imagens de prova, dois percentuais de acertos e dois percentuais de erros são calculados. Desta forma, a fim de representar os percentuais finais de acertos e erros de cada imagem, calcula-se as médias aritméticas de acertos e de erros desses pares.

A escolha do melhor conjunto de características para cada imagem é realizado comparando os 1.023 resultados de média de acertos e de erros. O conjunto de características que apresentar maior percentual da média de acertos e conseqüentemente menor percentual da média de erros, é considerado como o conjunto que melhor representa a classificação das duas tintas para cada imagem. Considerando o processamento das 5 imagens da base de escolha de características, tem-se seus resultados na Tabela 4.4:

Tabela 4.4: Resultado do melhor conjunto de características para cada imagem da base de escolha de características

Imagem	Conjunto de Características	Maior Percentual da Média de Acertos	Menor Percentual da Média de Erros
01	B	76,69	23,31
02	BSMY	70,38	29,62
03	SMY	68,25	31,75
04	GBSMY	77,26	22,74
05	S	63,75	36,25

Analisando os resultados dispostos na Tabela 4.4, nota-se que em nenhuma imagem repetiu-se o melhor conjunto de características. Este fato demonstra que, mesmo com todas as imagens contendo tintas de corante azul, seus valores de *pixels* não apresentam um padrão bem definido em relação às áreas comparadas com as imagens de prova.

A Tabela 4.4 apresenta os melhores resultados considerando cada imagem da base de escolha de características separadamente. A fim de quantificar qual o conjunto de características que melhor representa a classificação de todas as imagens desta base, os

valores de cada um dos conjuntos são obtidos para todas as imagens da base. Esses resultados são demonstrados na Tabela 4.5, como segue:

Tabela 4.5: Resultado da aplicação do melhor conjunto de características para cada imagem em todas as imagens da base de escolha de características

Imagem	Conjunto de Características	Maior Percentual da Média de Acertos	Menor Percentual da Média de Erros
01	B	76,69	23,31
	BSMY	66,75	33,25
	SMY	64,48	35,52
	GBSMY	65,65	34,35
	S	63,31	36,69
02	B	62,74	37,26
	BSMY	70,38	29,62
	SMY	70,38	29,62
	GBSMY	65,69	34,31
	S	67,48	32,52
03	B	63,50	36,50
	BSMY	68,24	31,76
	SMY	68,25	31,75
	GBSMY	61,85	38,15
	S	64,29	35,71
04	B	77,17	22,83
	BSMY	77,22	22,78
	SMY	76,58	23,42
	GBSMY	77,26	22,74
	S	60,25	39,75
05	B	56,82	43,18
	BSMY	63,66	36,34
	SMY	54,44	45,56
	GBSMY	61,26	38,74
	S	63,75	36,25

Assim, a média de resultados dos conjuntos de características são calculados para a definição das características que representam a melhor classificação das imagens da base de escolha de características. Estes valores são demonstrados na Tabela 4.6.

Tabela 4.6: Percentual médio dos resultados da aplicação do melhor conjunto de características para cada imagem em todas as imagens da base de escolha de características

Conjunto de Características	Média Final de Acertos	Média Final de Erros
B	67,38	32,62
BSMY	69,25	30,75
SMY	66,82	33,18
GBSMY	66,34	33,66
S	63,82	36,18

Os resultados da Tabela 4.6 demonstram que com 69,25% de média final de acertos e 30,75% de média final de erros, o conjunto composto pelos componentes B , S , M e Y é o que representa melhor a classificação das imagens da base de escolha de características.

Analisando os resultados demonstrados na Tabela 4.4, nota-se que os componentes individuais B , M e Y são selecionados em 3 conjuntos de características e o componente individual S é selecionado em 4 conjuntos de características. Além disso, o conjunto que contém os componentes S , M e Y são selecionados em 3 imagens. Isto representa que as informações contidas em todas as imagens da base são mais propícias de serem separadas, a fim de chegar às imagens de prova, através destes componentes do que por meio de qualquer outra combinação dos demais.

Conforme descrito na Seção 2.5, tem-se as seguintes características para justificar a escolha do processo por estes componentes:

- O componente B do modelo de cores RGB representa a cor azul, a qual é a base das cores das tintas utilizadas nos documentos analisados. Analisando a Tabela 4.4, nota-se que a imagem 01 apresentou como melhor característica apenas o componente B , o que contribui para evidenciar sua importância.
- O componente Y do modelo de cores CMYK representa a cor amarela, a qual possui valor complementar em relação ao valor do componente B do modelo RGB. Conforme visto anteriormente, a cor azul é a base das cores das tintas utilizadas nos documentos analisados.
- O componente S do modelo HSI representa o grau no qual a cor não está diluída no branco. Esta característica evidencia a importância das áreas onde foram depositadas quantidades diferenciadas de massa corante pelo instrumento escrevente. Analisando a Tabela 4.4, nota-se que a imagem 05 apresentou como melhor característica apenas o componente S , o que contribui para evidenciar sua importância.
- O componente M do modelo de cores CMYK representa a cor magenta, a qual possui valor complementar em relação ao componente G do modelo de cores RGB. Assim, sua composição é a soma dos valores dos componentes R e B deste mesmo modelo. Como o componente R possui pouca representatividade para a

formação das cores das tintas analisadas, conclui-se que grande parte do componente M é constituída pelo valor do componente B .

Além destas justificativas, analisando a Tabela 4.4 pode-se notar que o conjunto de características formado pelos componentes S , M e Y é selecionado em 3 imagens, conforme descrito anteriormente. Este fato evidencia que estes componentes agrupados são relevantes para o processamento destas imagens, ou seja, adiciona-se às suas justificativas individuais de escolha, a representação conjunta desses componentes.

Como um exemplo comparativo dentre os 10.230 resultados, tem-se a Figura 4.11 e a Figura 4.13 como imagens de prova, a Figura 4.12 e a Figura 4.14 como imagens resultantes da classificação com as características B , S , M e Y . O detalhamento dos resultados das imagens ilustradas na Figura 4.12 e na Figura 4.14, nomeadas de imagem da classificação do conteúdo original e imagem da classificação da alteração, são apresentados na Tabela 4.7.



Figura 4.11: Imagem exemplo da primeira prova

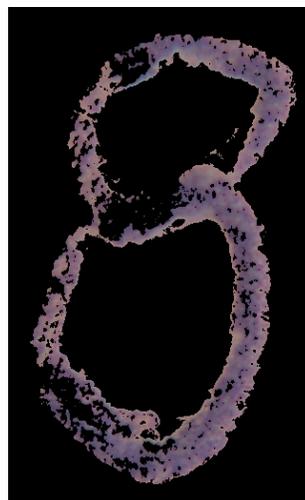


Figura 4.12: Imagem da classificação do conteúdo original, comparada à primeira prova

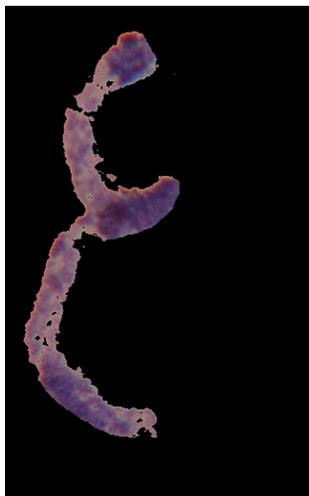


Figura 4.13: Imagem exemplo da segunda prova

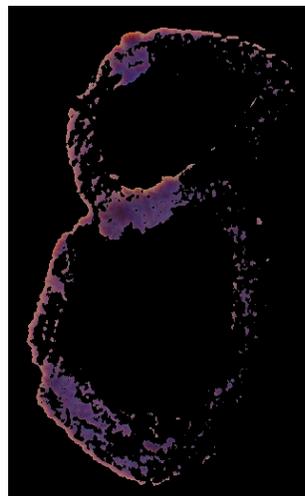


Figura 4.14: Imagem da classificação da alteração, comparada à segunda prova

Tabela 4.7: Resultados do exemplo do processo de escolha de características

Resultados	Imagem da Classificação do Conteúdo Original	Imagem da Classificação da Alteração
Percentual de valores positivos	71,42	69,34
Percentual de valores falso positivos	28,58	30,66
Taxa de acertos	71,42	69,34
Taxa de erros	28,58	30,66

Conforme descrito anteriormente, o protocolo de escolha de características, depois do processamento de todas as imagens de sua base, define o conjunto de características, que contém os componentes B , S , M e Y , para serem utilizadas na etapa de extração de características, descrita na próxima seção.

4.6. Extração de Características (E4)

A etapa de extração de características realiza a conversão dos valores dos *pixels* da imagem em informações que serão utilizadas pelo classificador do processo de separação de tintas (Seção 4.7). A etapa recebe as imagens contendo apenas as regiões de tinta da etapa de extração do fundo (Seção 4.4) e o conjunto de características que apresentou melhores resultados de classificação, gerado pelo protocolo de escolha de características (Seção 4.5).

Esta etapa percorre toda a imagem e analisa seus valores, originalmente representados pelo modelo de cores RGB. Como o conjunto de características definido pelo protocolo de escolha de características contém os componentes *B*, *S*, *M* e *Y*, faz-se necessário a conversão dos valores da imagem para o modelo de cores HSI para extração do componente *S* e a conversão para o modelo CMYK, para extração dos componentes *M* e *Y* (Seção 2.6).

Os resultados destas conversões representam os valores com proporções diferenciadas: o valor do componente *B* está contido no intervalo [0,255] e os demais estão contidos no intervalo [0,1]. Desta forma, todos os valores extraídos são normalizados para o intervalo [0,255], a fim de não favorecer alguma característica no processo de classificação.

O espaço de características utilizado pelo classificador do processo de separação de tintas é de dimensão 4, sendo que cada dimensão representa um dos componentes definidos pelo protocolo de escolha de características. Assim, os valores de características extraídos nesta etapa consistem nos dados das classes que são distribuídos neste espaço.

4.7. Separação das Tintas (E5)

A etapa de separação de tintas recebe uma imagem do processo de extração de fundo (Seção 4.4) e realiza a segmentação desta através de um algoritmo de classificação, com as características extraídas da imagem, descritas na seção anterior.

O processo de classificação utiliza o algoritmo K-Means (Seção 2.7.3) com seu espaço de características formado pelos valores provenientes do processo de extração de características (Seção anterior). Para o processo de classificação foram selecionados os seguintes parâmetros:

- **Número de características:** Os componentes *B*, *S*, *M* e *Y* dos modelos de cores RGB, HSI e CMYK. (4 características).
- **Número de classes:** As classes da tinta original e da tinta de alteração (2 classes).
- **Número de iterações:** Não foi definido limites de iterações, estas findam quando o critério de convergência é satisfeito.
- **Critério de convergência:** Quando não há mais movimentação alguma dos centros, ou seja, critério 10^{-3} .

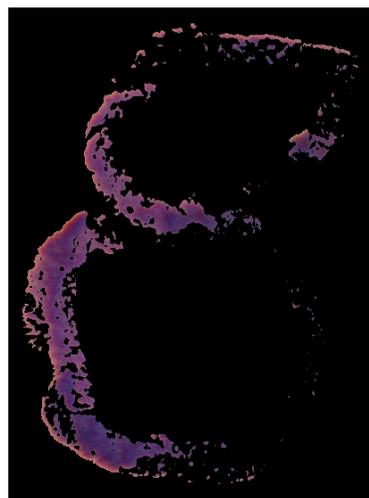
O processo de classificação resulta em duas imagens, uma contendo as informações de tinta original do documento e outra contendo as informações de tinta da alteração do documento, à luz do processo de classificação. Estas imagens são os resultados do método proposto, conforme ilustrado na Figura 4.15(b) e na Figura 4.15(c) através de um exemplo de documento que foi submetido a este processo, ilustrado na Figura 4.15(a).



(a)



(b)



(c)

Figura 4.15: Imagens de exemplo do início e término do processo. (a) Imagem original sem tratamentos de um documento para o experimento. (b) Exemplo de resultado do método proposto. Imagem da classificação do conteúdo original do documento. (c) Exemplo de resultado do método proposto. Imagem da classificação do conteúdo alterado do documento.

A Figura 4.15(b) e a Figura 4.15(c) demonstram apenas um exemplo de resultado do método proposto. A quantificação dos resultados da submissão da base de dados do experimento ao método proposto é descrita e analisada no Capítulo 5 deste documento.

4.8. Comentários Finais

Este capítulo demonstra todas as etapas e protocolos envolvidos no método proposto por este estudo. As definições de técnicas e demais características do método são justificadas. O próximo capítulo apresenta a quantificação dos resultados da submissão da base de dados do experimento ao método proposto e uma análise sobre os resultados.

Capítulo 5

5 Experimentos e Resultados

Este capítulo descreve os experimentos realizados sobre o método proposto, bem como demonstra e analisa seus resultados. Imagens da base de dados são submetidas a outros algoritmos de segmentação e seus resultados são analisados.

5.1. Experimentos e Análise Quantitativa dos Resultados

Os experimentos foram realizados com imagens definidas através do protocolo da base de dados (Seção 4.1). Foram submetidas ao método proposto 40 imagens com incidência de tintas com corante azul, sendo cada imagem com dois tipos de tintas diferentes.

Como pré-requisito para a execução do método proposto é necessário definir o conjunto de características que serão utilizadas através do protocolo de escolha de características (Seção 4.5). Na execução do protocolo foram escolhidas como características os componentes B , S , M e Y , dos modelos de cores RGB, HSI e CMYK.

As etapas de aquisição, de pré-tratamento, de extração de fundo, extração de características e de separação de tintas do método proposto foram executados para cada imagem da base de dados, gerando duas imagens de resultado para cada uma destas. Estas imagens possuem a segmentação das duas regiões de tinta de cada imagem pré-tratada (Capítulo 4).

Quando todos os resultados do processo foram gerados, realizou-se o processo de quantificação destes. Para tal, foi necessário um método que identificasse quanto o classificador conseguiu separar das duas tintas contidas na imagem. Este processo de

quantificação foi semelhante ao definido no protocolo de escolha de características (Seção 4.5), porém excluiu-se a necessidade de quantificação dos vários conjuntos de características. Assim, o processo resumiu-se em:

- Criar duas imagens de prova para cada imagem da base;
- Calcular os valores positivos e falso positivos comparando os valores da imagem resultante do processo com as imagens de prova;
- Calcular os percentuais de acerto e de erro em relação aos valores positivo e falso positivo;
- Calcular as médias aritméticas dos percentuais de acerto e de erro em relação às duas imagens resultantes, sendo este o resultado final de cada imagem;
- Calcular a média aritmética do resultado final de cada imagem, sendo este o resultado médio final do experimento.

O percentual médio de acertos foi de 61,89%, o que não é considerado seguro para determinar que existe uma alteração em um documento. Porém, considerando os equipamentos utilizados, a ausência da necessidade de definição de parâmetros para o método e a comparação com outros métodos de segmentação (Seção 5.2), nota-se que o método proposto apresentou resultados satisfatórios que podem ser estudados e melhorados (Capítulo 6). A Tabela 5.1 demonstra os resultados e valores de medidas de estatística para a análise destes.

Tabela 5.1: Resultados finais quantificados do método proposto

Medidas	Resultados	
	Acertos (%)	Erros (%)
Menor	50,08	23,97
Maior	76,03	49,92
Amplitude	25,95	25,95
Média	61,89	38,11
Mediana	59,42	40,58
Desvio Padrão	7,71	7,71
Curtose	-0,99	-0,99
Tipo da Função	Platicúrtica	Platicúrtica

Em uma análise inicial, nota-se que dentre as imagens analisadas o maior resultado de acertos foi de 76,03% e o pior foi de 49,92%, com uma amplitude de 25,95%. Esta amplitude

foi a primeira indicação de que existem casos onde os resultados são dispersos. Adicionalmente, o desvio padrão de 7,71% indica que 62,5% das imagens estão dentro dos limites do desvio padrão e 37,5% encontram-se fora destes limites. Isto evidencia tal dispersão pois os dados que se encontram fora desses limites estão próximos do melhor e do pior resultado e o valor do desvio padrão encontra-se distante da média dos resultados.

O gráfico da Figura 5.1 demonstra a função de densidade da probabilidade considerando a distribuição dos valores dos resultados. Este gráfico demonstra o relacionamento dos resultados em relação à média destes. Nota-se no gráfico a assimetria dos valores em relação a uma distribuição Gaussiana (distribuição normal), esta assimetria de valores é confirmada considerando que a média dos valores é de 61,89% e a mediana é de 59,42%. Desta forma, conclui-se que a maioria dos resultados apresentam valores maiores do que a mediana destes. Estes fatos indicam que os resultados não estão bem distribuídos entre o melhor e o pior caso.

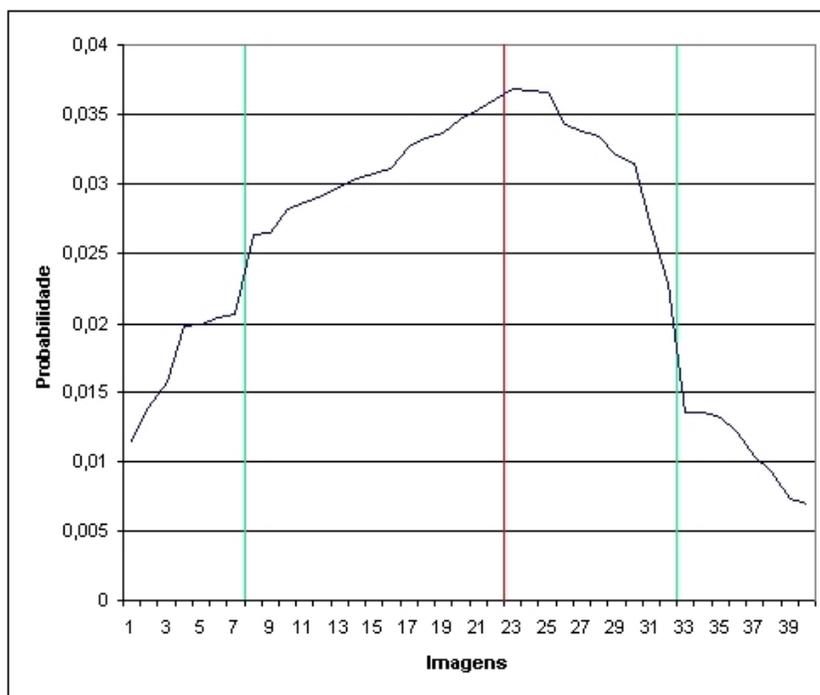


Figura 5.1: Gráfico da função de densidade da probabilidade demonstrando a distribuição da média dos resultados (linha azul), a média (linha vermelha) e os limites do desvio padrão (linhas verdes)

Outro fator que pode ser considerado para caracterizar os resultados é o achatamento da distribuição em relação a uma distribuição Gaussiana padrão. O valor de curtose da

distribuição é de $-0,99\%$, o que significa que esta possui valores mais dispersos do que uma distribuição Gaussiana, ou seja, é uma distribuição platicúrtica. Isto confirma, conforme analisado anteriormente, que os resultados apresentam uma dispersão acentuada em relação à média.

As constatações de que os resultados possuem uma média que não é satisfatória, estão dispersos em relação a esta média e de que esta dispersão não possui um padrão, indicam que fatores prejudicaram a obtenção de melhores resultados. Dentre os fatores analisados a seguir, o que mais influenciou negativamente está relacionado com o equipamento de aquisição de imagens.

Na etapa do processo de aquisição, a máquina fotográfica digital apresenta limitações de hardware para a digitalização de informações das imagens. A máquina digital utilizada por este estudo possui sensores CCD de câmeras convencionais, que não são capazes de distinguir faixas muito próximas de frequência do espectro de cores (Seção 2.4.1). Desta forma, a média e a dispersão obtidas pelo método proposto justifica-se pelo processo de aquisição não ser capaz de colher informações suficientes para a distinção de diferentes tipos de tintas.

No momento da escrita, utilizando uma caneta esferográfica, a esfera localizada na extremidade da caneta através da rotação sobre seu eixo é embebida de massa corante e deposita esta massa na superfície de escrita (Seção 2.1.4). Este processo deposita diferentes quantidades de tinta na região de escrita dependendo principalmente do movimento realizado pelo autor, fato que pode ser melhor observado através da equalização do histograma (Componente H do modelo de cores HSI) de uma imagem da base de dados na Figura 5.2(a) e na Figura 5.2(b), por exemplo. A equalização do histograma é um processo de realce onde realiza-se um aumento na escala dinâmica dos *pixels* [GW00] e a utilização do componente H possibilita que o realce seja realizado sobre a matiz da imagem.

As superfícies onde foram realizadas as escritas dos experimentos é constituída de papel que possui a propriedade de absorção de certos tipos de componentes, ou seja, a tinta mistura-se com a composição do papel. Neste caso, regiões onde foram depositadas pequenas quantidades de tinta apresentam uma composição dominante da coloração do papel e as regiões com maiores quantidades de tinta apresentam composição dominante da tinta. Assim, as diferenças de composição destas áreas dos documentos representam diferenças nos valores dos *pixels* (Figura 5.2(b)), que são a única fonte de informações para todo o processo de

separação de tintas. Esta constatação é uma característica inerente a todos os documentos, onde a utilização de equipamentos com maior sensibilidade para distinção de faixas próximas do espectro luminoso podem obter informações suficientes da imagem para o tratamento de tais características.

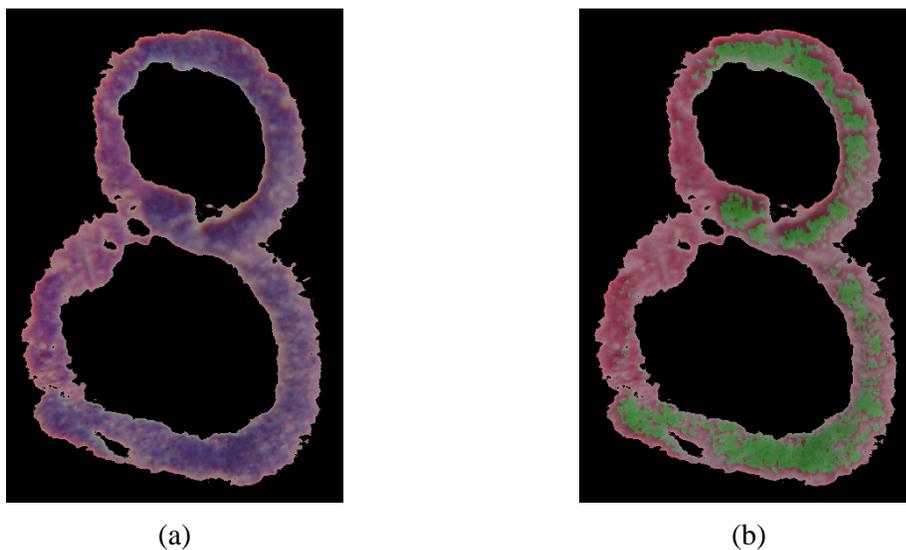


Figura 5.2: Ilustração do depósito de diferenças quantidades de tinta em diferentes regiões da escrita. (a) Imagem sem fundo com diferenças de quantidades de tinta em seus traçados. (b) Imagem com seu histograma equalizado (Componente H do modelo HSI), onde a região com coloração verde representa a maior incidência de tinta.

Um outro fator que influenciou o resultado final da segmentação é a definição da base de escolha de características (Seção 4.1). Como a quantidade de imagens desta base é pequena (5 imagens), uma análise comparativa da distribuição desta com a distribuição dos valores dos resultados dos experimentos torna-se pouco confiável. Contudo, analisando que os resultados da escolha de características possui uma distribuição leptocúrtica, conclui-se que esse é um indício de que esta base não representa satisfatoriamente a base de experimentos. Outro fator que reforça esta conclusão é proveniente da comparação da Tabela 4.6 e da Tabela 5.1, nota-se que o resultado médio de acertos da base de escolha de características é de 69,25% e o da base do experimento é de 61,89%. Considerando que o desvio padrão dos acertos da quantificação da base de escolha de características é de 5,08%, o resultado médio da base do experimento está fora dos limites desse desvio padrão, no caso da aproximação de uma distribuição normal. Desta forma, constata-se que as imagens selecionadas são pouco representativas em relação à base de dados do experimento. O acréscimo de espécimes de

imagens nesta base ou a escolha de outras imagens pode influenciar nos resultados. Porém, ressalta-se que as informações obtidas das imagens são insuficientes para o processo, conforme descrito anteriormente, o que significa que a aquisição de imagens espectrais poderia fornecer informações suficientes para que esta base fosse representativa, sem a necessidade da inclusão de novas imagens.

O processo de separação de tintas (Seção 4.7) utiliza o classificador K-Means com as características extraídas representando os valores dos *pixels*, através de componentes dos modelos de cores RGB, CMYK e HSI. Considerando apenas os resultados do protocolo de escolha de características, nota-se que o resultado da média de acertos de 69,25% está abaixo das expectativas, mesmo com esta pequena base de dados (5 imagens). No caso da análise dos resultados do método proposto, a média é ainda menor. Assim, constatou-se que a classificação por valores de *pixels* utilizando componentes dos modelos de cores RGB, CMYK e HSI, não representam informações suficientes para classificar as regiões das imagens com diferentes tintas. Esta carência de informações é justificada por dois fatores:

- Quanto ao tipo das características, a falta de informações espaciais e de vizinhança dos *pixels* favorece a segmentação de pequenas regiões descontínuas e pouco expressivas para alterações documentais (Figura 5.3(a) e Figura 5.3(b)).
- Quanto à qualidade das características, o principal fator encontra-se na incapacidade do equipamento de aquisição de distinguir faixas próximas do espectro luminoso, conforme descrito anteriormente. Este fator proporciona a identificação de faixas diferentes do espectro como faixas idênticas, o que não permite a distinção de algumas regiões de tintas diferentes, gerando áreas descontínuas de segmentação (Figura 5.3(a) e Figura 5.3(b)).

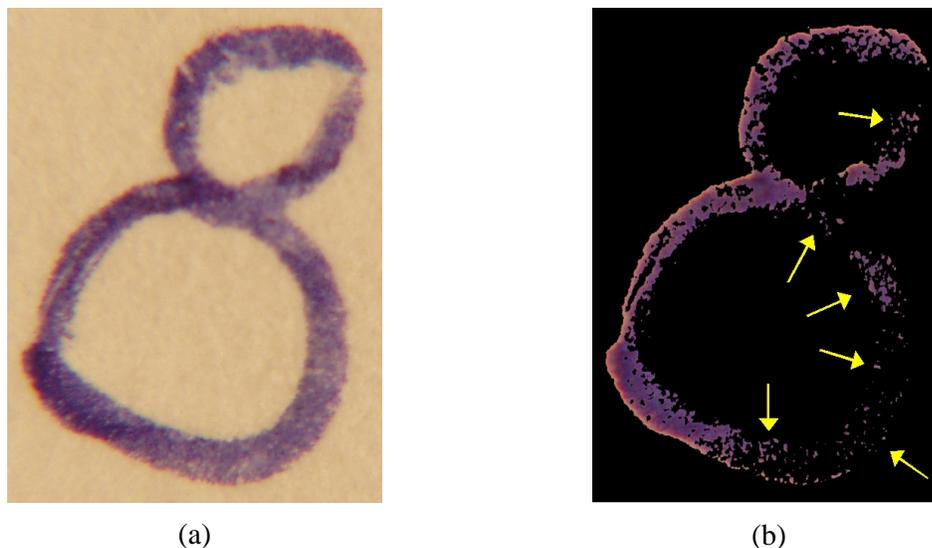


Figura 5.3: Descontinuidade de pixels em uma mesma classe. (a) Imagem da base de dados. (b) Imagem segmentado demonstrando regiões de uma classe que não apresentam continuidade.

Para a realização da quantificação dos resultados, imagens de prova foram geradas manualmente para a comparação dos *pixels* que foram segmentados. A criação destas provas utiliza informações *a priori* sobre as alterações realizadas, porém existem regiões onde as tintas utilizadas são superpostas. Essas regiões são separadas nas provas através de uma análise da tinta que se apresenta dominante na composição das cores dos *pixels*, contudo suas informações de cores não são idênticas ao restante da escrita com esta tinta. Esses valores diferenciados representam dispersões de valores no espaço de características do classificador, o que influencia na definição dos centros através da distância Euclidiana aplicada no classificador. A comparação considerando a imagem pré-tratada ilustrada na Figura 5.4(a) e as imagens de prova ilustradas na Figura 5.4(b) e na Figura 5.4(c), demonstra que a área onde foram inseridas duas tintas diferentes apresenta uma composição visualmente diferenciada.

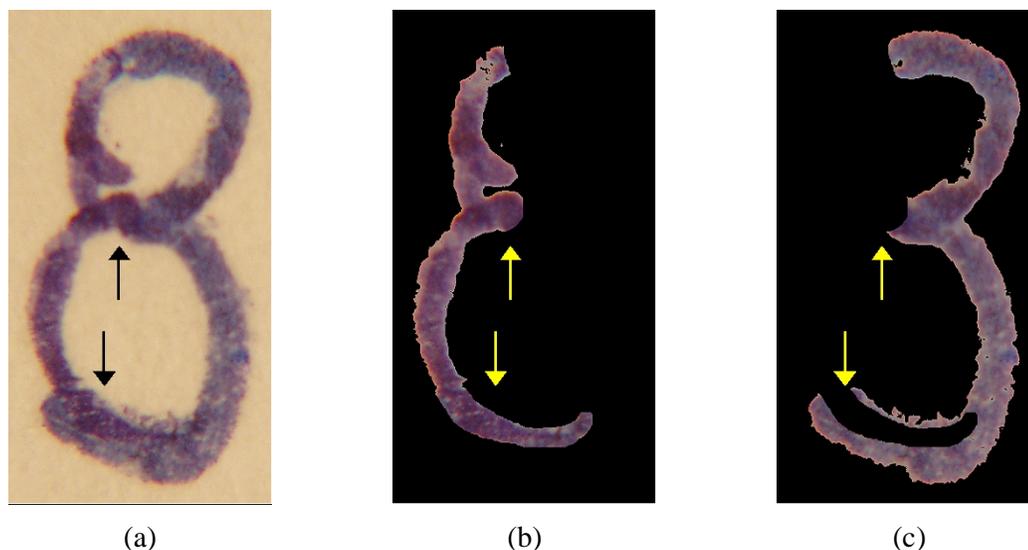


Figura 5.4: Superposição de tintas. (a) Imagem pré-tratada demonstrando 2 regiões onde existe superposição de tintas. (b) Imagem de prova 1 demonstrando o tratamento para superposição de tintas. (c) Imagem de prova 2 demonstrando o tratamento para superposição de tintas.

Dois exemplos dos resultados das etapas do método proposto são ilustrados nas imagens da Figura 5.5 e da Figura 5.6, as quais se referem aos exemplos 1 e 2, respectivamente. O exemplo 1 demonstra os resultados da imagem que apresentou a menor média dentre os resultados (50,08%) e o exemplo 2 a maior média (76,03%).

Considerando os fatores que influenciam nos resultados de segmentação das imagens, nota-se que ambas as imagens apresentam regiões de traçado onde foram depositadas diferentes quantidades de tinta (Figura 5.5(b) e Figura 5.6(b)).

No exemplo 1, a composição das duas tintas utilizadas apresentam características de cor muito parecidas, o que não favorece no resultado final da segmentação (Figura 5.5(e) e Figura 5.5(f)). No exemplo 2, os resultados de segmentação apresentam a imagem segmentada do conteúdo original (Figura 5.6(e)) com regiões descontínuas provenientes de informações que deveriam ser classificadas na imagem segmentada do conteúdo alterado (Figura 5.6(f)), que por sua vez apresenta poucas regiões descontínuas mas com falta de informações.

Ambos os resultados apresentam sobreposições de tintas, no exemplo 1 as imagens de prova (Figura 5.5(c) e Figura 5.5(d)) foram geradas atribuindo as áreas de sobreposição à prova da classe 1, por esta apresentar regiões de maior similaridade com a área de

sobreposição. As imagens de prova do exemplo 2 (Figura 5.6(c) e Figura 5.6(d)) foram geradas através da divisão da área de sobreposição entre estas, visto que nenhuma das áreas possui uma similaridade mais acentuada com a região de sobreposição.

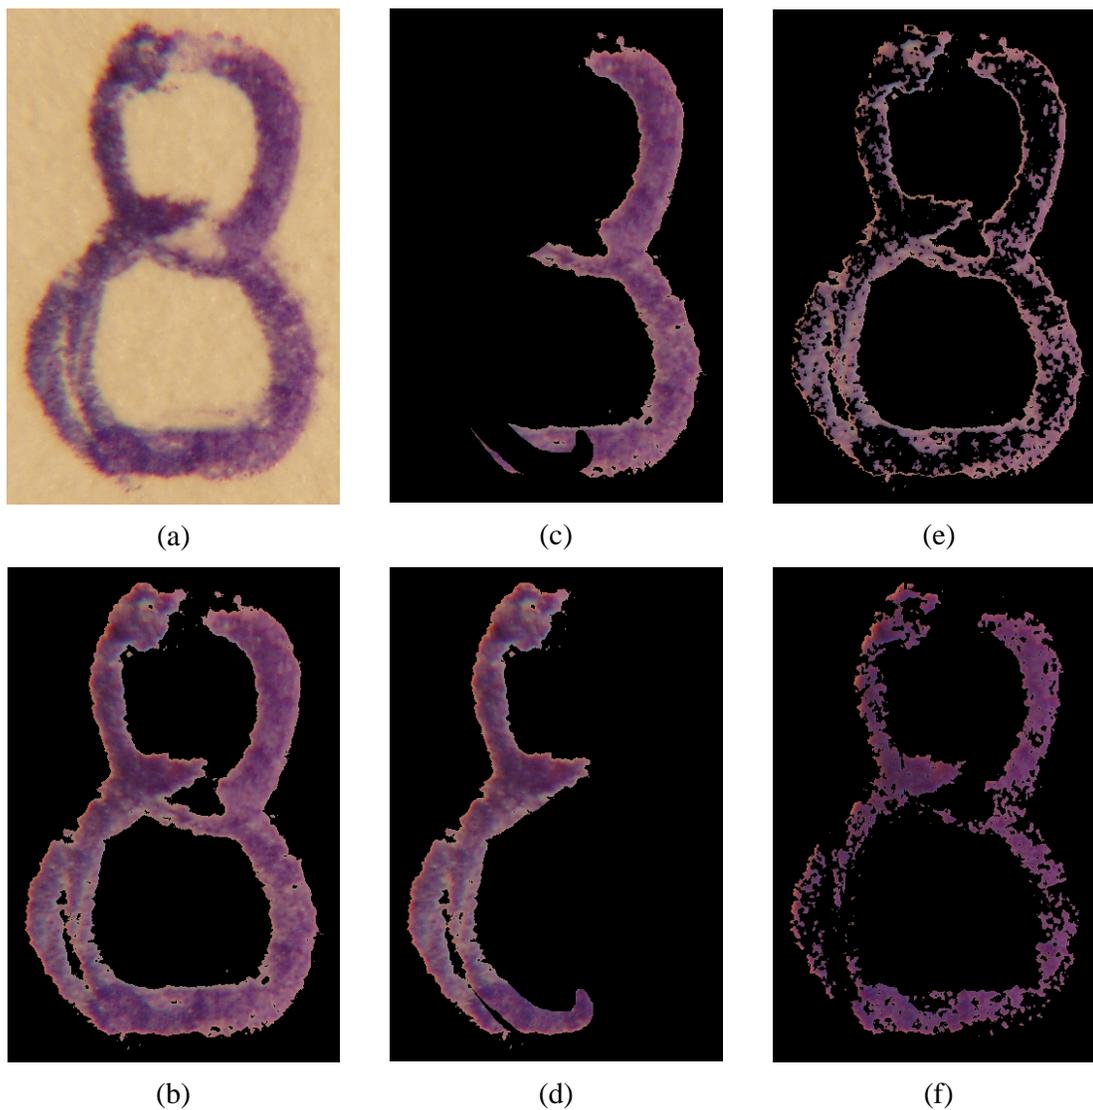


Figura 5.5: Exemplo 1 da menor média dentre os resultados: (a) Resultado do processo de pré-tratamento; (b) Resultado do processo de extração do fundo; (c) Imagem da prova do conteúdo original; (d) Imagem da prova do conteúdo alterado; (e) Resultado do processo de separação de tintas representando o conteúdo original; (f) Resultado do processo de separação de tintas representando o conteúdo alterado

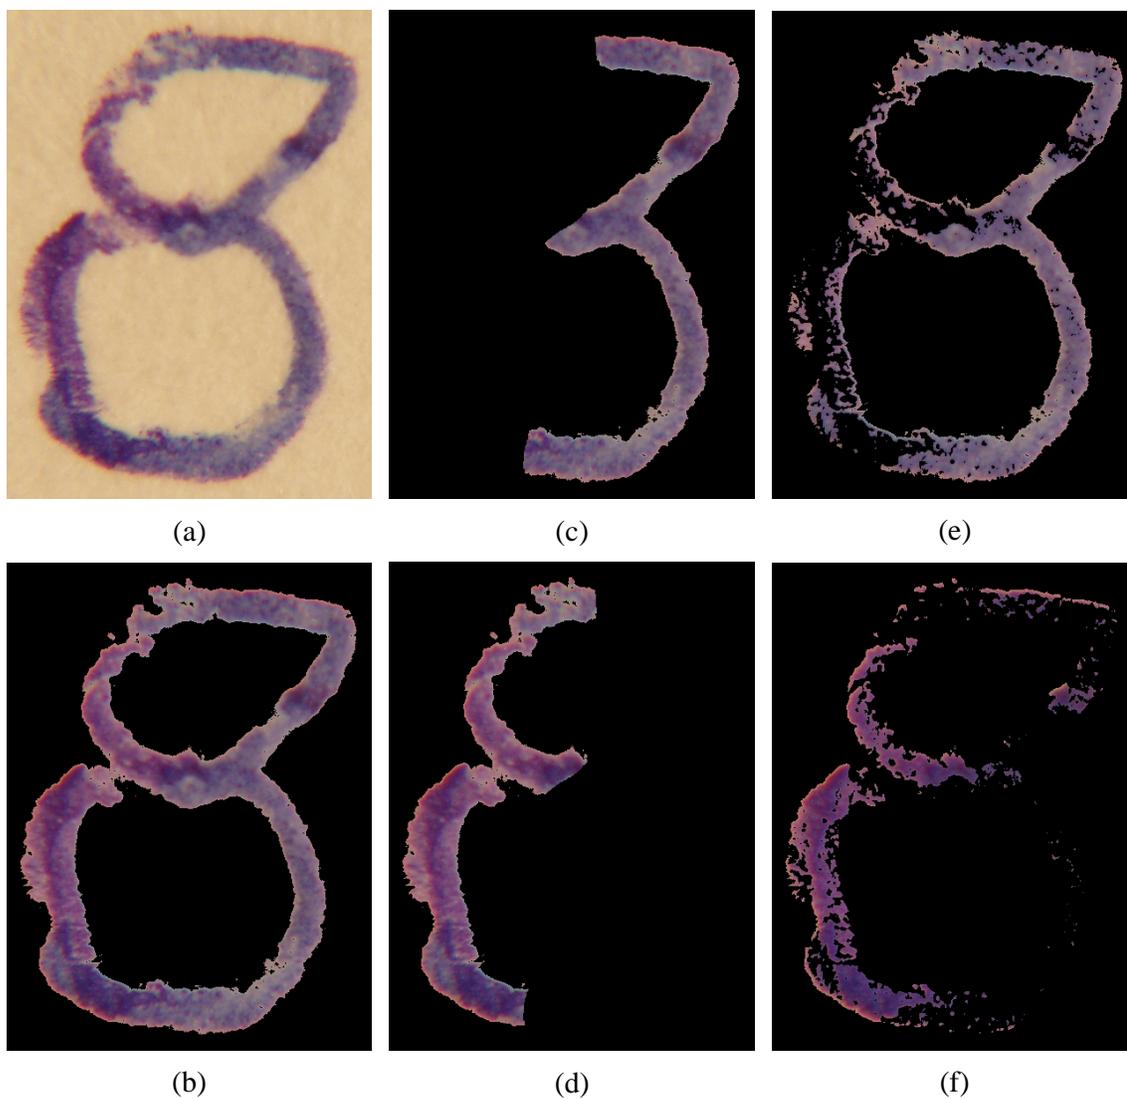


Figura 5.6: Exemplo 2 da maior média dentre os resultados: (a) Resultado do processo de pré-tratamento; (b) Resultado do processo de extração do fundo; (c) Imagem da prova do conteúdo original; (d) Imagem da prova do conteúdo alterado; (e) Resultado do processo de separação de tintas representando o conteúdo original; (f) Resultado do processo de separação de tintas representando o conteúdo alterado

5.2. Análise Visual dos Resultados de outros Métodos de Segmentação

Este método de análise visual identifica características dos resultados de outros métodos de segmentação de imagens coloridas, sobre imagens selecionadas da base de dados. Foram utilizados dois métodos de segmentação para análise de seus resultados:

- Um método automático de segmentação de imagens coloridas chamado JSEG proposto por Deng, Manjunath e Shin [DMS99] (Seção 3.1.3). Este método é baseado em extração de regiões e possui atuação geral, ou seja, processa diferentes tipos de imagens.
- Um método variacional chamado VIS que utiliza cores e texturas realizando uma difusão da imagem baseada em um conjunto de *edge vectors*. O método foi proposto por Sumengen, Kenney e Manjunath [SKM04] (Seção 3.1.1) e também possui atuação em diferentes tipos de imagens. Ressalta-se que diversos testes foram realizados com este método, a fim de calibrar os parâmetros na busca dos resultados mais adequados para o problema em estudo.

Estes dois métodos são fornecidos para testes pela comunidade e não foram implementados neste trabalho. O método JSEG é fornecido por [DM99] e o método VIS é fornecido por [SKM04].

Um procedimento de análise quantitativa para comparação entre os resultados desses métodos e o resultado do método proposto não é realizado pelos seguintes fatores:

- Os métodos analisados apresentam etapas onde realiza-se união de regiões da imagem, tanto pela similaridade de cores, quanto pelo comportamento de texturas. Métodos que utilizam análise de regiões, normalmente apresentam resultados onde as regiões segmentadas possuem uma característica contínua de *pixels*. Como o método proposto não considera regiões, este apresenta como resultado *pixels* que podem estar dispersos pela área da imagem. Ou seja, com as regiões possuindo *pixels* descontínuos pode não ser possível a delimitação das classes através de um limite de regiões.
- O método proposto considera que a imagem analisada deve possuir apenas duas regiões: os dois tipos de tinta. Por sua vez, os demais métodos analisados não possuem parametrização em relação à quantidade de regiões que devem ser identificadas. Desta forma, estes métodos apresentam a segmentação da imagem em uma quantidade de regiões que depende da análise individual de cada método.

Foram selecionadas 2 imagens da base de dados para serem submetidas aos métodos: a imagem 1 apresentou o menor resultado na aplicação do método proposto e a imagem 2

apresentou o maior resultado. As imagens apresentam seu fundo extraído, a fim de auxiliar a análise dos resultados.

Em uma análise inicial, os dois métodos não segmentaram as imagens em duas regiões de tintas, seguindo os resultados do método proposto (Figura 5.7(a) à Figura 5.8(e)).

O método de segmentação JSEG assemelha-se com o método proposto, pela ausência da necessidade de definição de parâmetros que possam influenciar no resultado da segmentação. Este fato proporciona independência do método em relação a conhecimentos *a priori* das imagens que serão analisadas. O método apresenta os seus resultados (Figura 5.7(b) e Figura 5.8 (b)) com uma quantidade de regiões maior do que duas, nota-se que essas regiões são principalmente provenientes da diferença da quantidade de tinta depositada nos traçados das amostras. Adicionalmente, os resultados desse método apresentam regiões da imagem que não foram segmentadas.

O método de segmentação VIS apresenta melhores resultados em relação ao método JSEG e ao método proposto, porém este necessita da definição de 3 parâmetros para sua execução: (a) necessidade de análise de texturas; (b) escala mínima de segmentação; (c) nível de similaridade para união de regiões. Estes parâmetros representam uma grande dependência do método, conforme pode ser observado comparando a Figura 5.7(c) com resultados de exemplos de variação dos seus parâmetros (Figura 5.9(a) e Figura 5.9(b)). Assim, é necessário um conhecimento *a priori* sobre as imagens analisadas e a realização de vários testes de calibração para a definição do resultado mais adequado. Os resultados selecionados como os mais condizentes com a separação das duas tintas, apresentam mais do que duas regiões para cada imagem. Nota-se que a quantidade de tinta diferenciada depositada nos traçados não influenciam tão significativamente nos resultados, ao contrário do verificado no método proposto e no método JSEG.

Os resultados do método proposto (Figura 5.7(d), Figura 5.7(e), Figura 5.8(d) e Figura 5.8(e)) demonstram comportamentos de erros de segmentação similares em relação aos resultados do método JSEG, por este também não ser parametrizado. Em relação aos resultados do método VIS, este apresentou resultados mais próximos da segmentação ideal das tintas, porém foi necessário calibrar os parâmetros com valores específicos para cada imagem analisada. Nota-se, em relação aos três métodos, que a falta de informações

fornechas pelo processo de aquisição das imagens propiciou para que todos os resultados não fossem satisfatórios, em relação à segmentação das tintas.

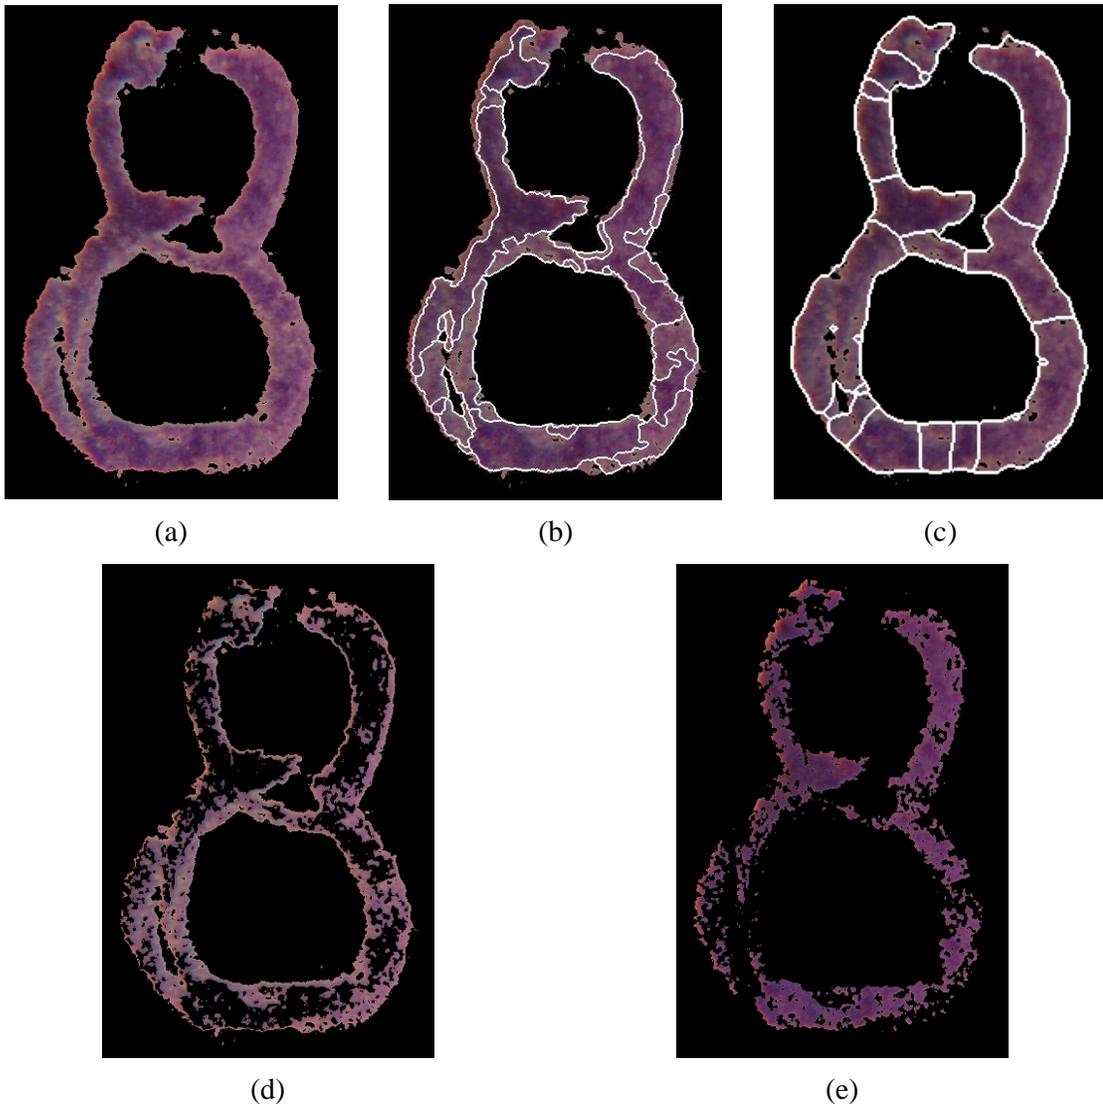


Figura 5.7: Resultados Imagem 1: (a) Resultado do processo de extração do fundo para ser utilizado por outros métodos. (b) Resultado do método JSEG [DMS99]. (c) Resultado do método VIS [SKM04]. Parâmetros: usar apenas cores, escala 10 de segmentação mínima e *balanced*. (d) Resultado da primeira região segmentada do método proposto. (e) Resultado da segunda região segmentada do método proposto.

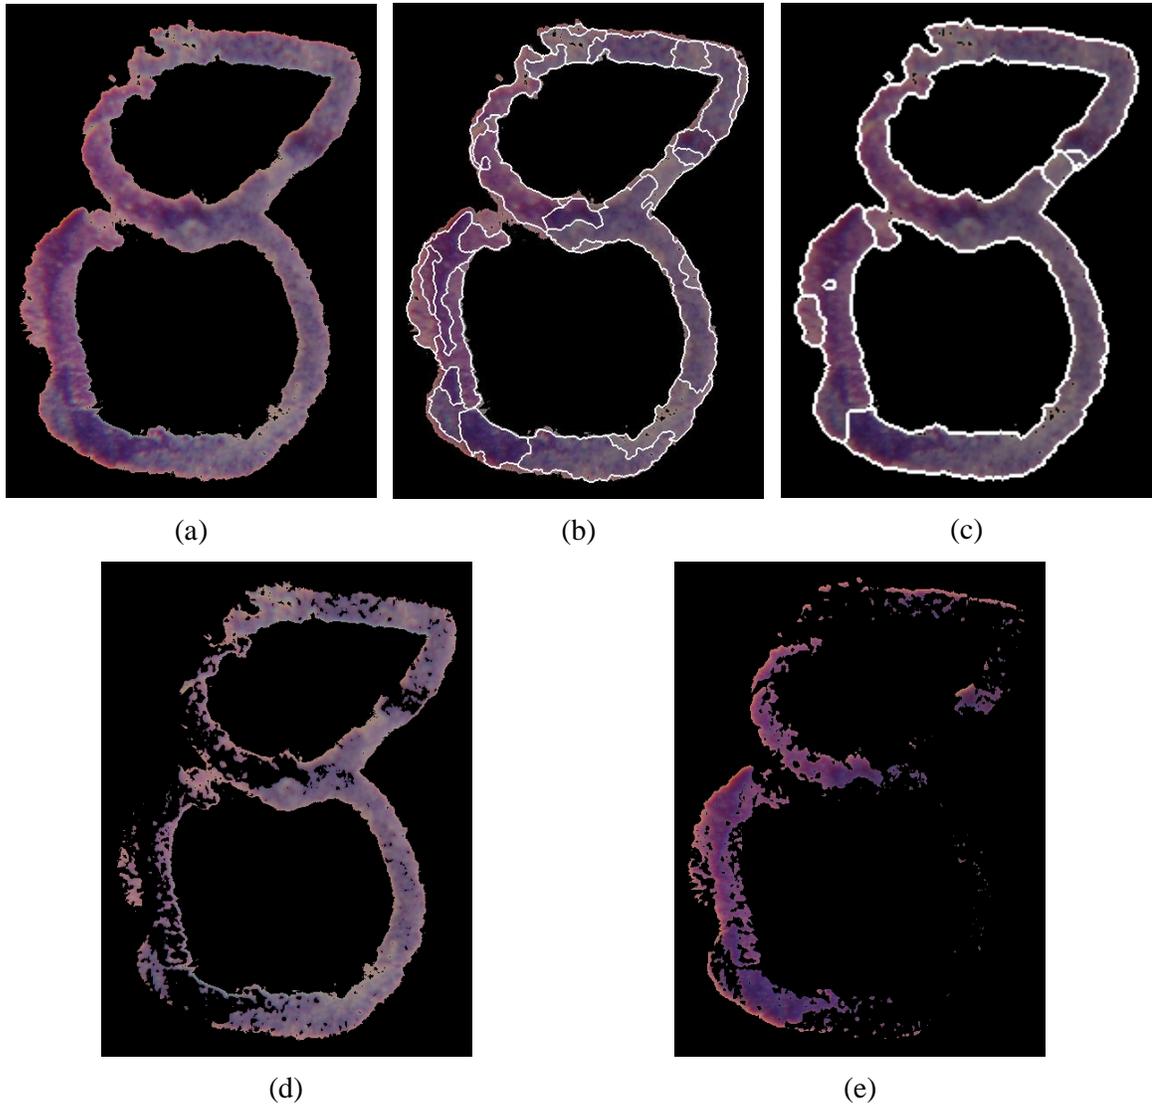


Figura 5.8: Resultados Imagem 1: (a) Resultado do processo de extração do fundo para ser utilizado por outros métodos. (b) Resultado do método JSEG [DMS99]. (c) Resultado do método VIS [SKM04]. Parâmetros: usar apenas cores, escala 3 de segmentação mínima e *undersegment*. (d) Resultado da primeira região segmentada do método proposto. (e) Resultado da segunda região segmentada do método proposto.

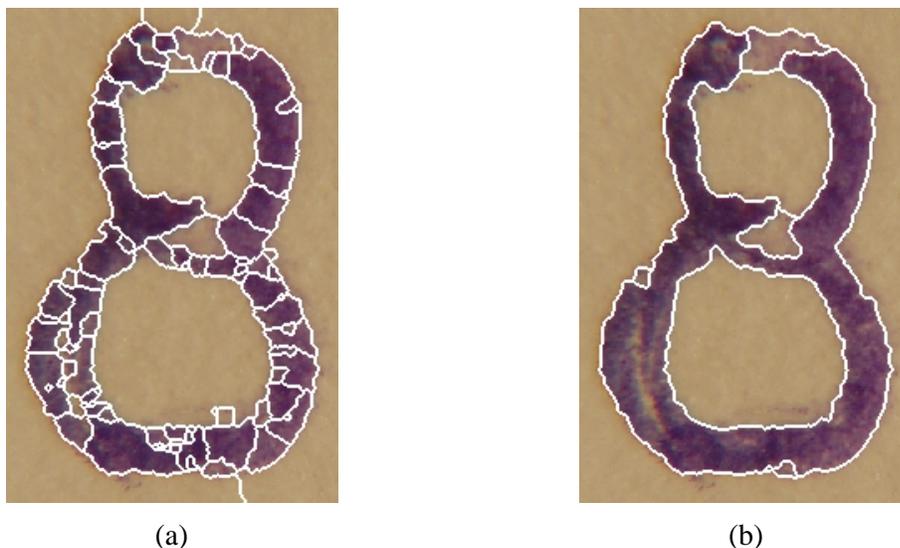


Figura 5.9: Resultados do método VIS [SKM04]. (a) Parâmetros: usar apenas cores, escala 1 de segmentação mínima e *oversegment*. (b) Parâmetros: usar apenas cores, escala 5 de segmentação mínima e *undersegment*.

5.3. Comentários Finais

Este capítulo demonstra os experimentos realizados sobre o método proposto e os resultados gerados por estes. Os resultados são analisados ressaltando seus pontos positivos e negativos e identificando os fatores que influenciam nos resultados obtidos. São realizadas análises visuais dos resultados obtidos pelo método não-parametrizado JSEG e pelo método parametrizado VIS. Nenhum dos métodos apresenta a segmentação ideal das imagens em duas regiões, contendo as duas tintas utilizadas para a confecção de cada amostra. O principal fator que influenciou nos resultados foi o conjunto de equipamentos utilizados no processo de aquisição. O método JSEG, que por não ser parametrizado se aproxima mais do método proposto, apresenta resultados com influência das regiões dos traçados onde foram depositadas maiores quantidades de tinta. O método VIS apresenta resultados mais adequados com a separação de tintas, porém é um método fortemente dependente da calibração de seus parâmetros, o que obriga o perito em grafoscopia a possuir um conhecimento *a priori* sobre as áreas do documento que possuem alterações, conhecimento este que nem sempre o perito possui.

6 Conclusão e Trabalhos Futuros

Neste capítulo são apresentadas as conclusões obtidas através do estudo realizado, bem como sugestões para trabalhos futuros.

6.1. Conclusão

O método proposto apresenta uma nova abordagem para separação de tintas em documentos forenses questionados através da classificação dos valores dos *pixels* convertidos nos modelos de cores RGB, HSI e CMYK. Foram detalhadas as etapas do método proposto de aquisição, pré-tratamento, extração de fundo e separação de tintas, bem como os protocolos da base de dados e da escolha de características. Experimentos foram realizados e seus resultados foram descritos e analisados. Por fim, as conclusões deste estudo são:

- O objetivo principal do método proposto, segmentar regiões com diferentes tintas, foi atingido. Porém apresenta uma média de acertos de 61,89%, o que não é considerado satisfatório para definir com exatidão regiões que apresentam alterações documentais. As limitações do método encontram-se principalmente no processo de aquisição das imagens. Foi utilizado um conjunto de equipamentos de baixo custo e suficiente para o processo de aquisição de imagens. A câmera fotográfica digital proposta utiliza um sensor CCD, que não é capaz de distinguir faixas muito próximas de frequência do espectro de cores. Assim, a câmera não conseguiu digitalizar informações suficientes das imagens para uma segmentação mais precisa das tintas.
- A base de dados criada em laboratório possui imagens de documentos que apresentam simulações de alterações documentais. Os documentos foram criados com a utilização de canetas esferográficas com diferentes pigmentações de corante azul. A digitalização destes documentos gerou imagens com uma quantidade insuficiente de informações para o tratamento pelo método proposto. Ressalta-se que, como observado na relação das canetas utilizadas descrita na Seção A.2.4, as

canetas Pilot BP-S 0,7 mm e Pilot BP-S Grip 1,0 mm provavelmente possuem a mesma composição química de corante, porém informações do fabricante sobre corante não foram encontradas. Assim, os testes realizados que envolvem estas canetas podem ter contribuído negativamente nos resultados.

- O processo de separação de fundo das imagens pré-tratadas apresentou resultados satisfatórios em geral, ou seja, o algoritmo classificou as regiões de tinta e de fundo de tal forma que estas pertenceram a classes distintas. Porém, alguns casos onde houve menor incidência de tinta sobre a superfície do papel não foram classificados adequadamente. Este fato deve-se principalmente ao processo de aquisição não fornecer informações suficientes sobre o espectro de cores refletidas, ou seja, informações que propiciassem ao método de classificação a identificação de que essas regiões possuem uma composição superior de papel em relação à tinta.
- Foi criado um método de segmentação não-parametrizado que considera apenas informações de cores dos *pixels*. O método utiliza o algoritmo de classificação K-Means que utiliza em seu espaço de características os valores dos *pixels* das imagens, convertidos nos componentes dos modelos de cores RGB, HSI e CMYK. Apenas o uso destes valores como características demonstrou-se insuficiente para classificar as regiões com tinta das imagens, pois apresentou resultados com descontinuidades de *pixels*. As descontinuidades foram notadas principalmente em regiões com diferente quantidade de tinta no mesmo traçado. Estas descontinuidades são justificadas pela ausência de informações no espaço de características referentes à posições espaciais e relacionamentos de vizinhança dos *pixels*. Porém são justificadas principalmente pelo fato do sensor CCD agrupar valores de frequências muito próximas, fazendo assim com que regiões com pigmentos de tinta diferentes tenham a mesma representação na imagem digitalizada.
- Adicionalmente, testes realizados com outros métodos de segmentação não apresentaram resultados satisfatórios, justificando assim a falta de informações fornecidas pelo processo de aquisição. O método não-parametrizado JSEG gerou resultados com a segmentação de muitas regiões. O método parametrizado VIS

apresentou melhores resultados depois da calibração de seus parâmetros, individualmente para cada imagem analisada.

O método proposto apresenta resultados que não são suficientes para serem utilizados em perícias. Porém, como o método proposto não requer parâmetros, os resultados obtidos indicam que o caminho seguido é promissor, possibilitando a continuidade das pesquisas para aperfeiçoamento do mesmo.

6.2. Trabalhos Futuros

Os trabalhos futuros propostos em relação a este estudo destinam-se à expansão da atuação deste e à melhora de seus resultados, como segue:

- Utilizar no processo de aquisição equipamentos que digitalizam imagens com informações mais precisas em relação ao espectro de cores. Estes equipamentos fornecem informações suficientes para que as regiões com incidência de diferentes tintas possam ser diferenciadas com maior exatidão.
- Incluir na base de dados documentos criados através de canetas com diferentes pigmentos de corantes preto e vermelho, pois estas também são utilizadas em documentos forenses.
- Diversificar o tipo das características utilizadas através de informações espaciais e de vizinhança dos *pixels*. Estas informações podem contribuir para uma melhora dos resultados, visto que alterações documentais normalmente possuem a característica de se encontrarem em regiões próximas na imagem, ou seja, as alterações possuem um comportamento contínuo na distribuição dos *pixels* nas imagens.
- Ainda considerando a descontinuidade dos *pixels* dos resultados, a combinação do método proposto com uma análise por crescimento de regiões possui uma tendência de segmentar as imagens em regiões menos descontínuas. Comprova-se este fato através da análise dos métodos JSEG [DMS99] e VIS [SKM04], onde os resultados possuem uma tendência de continuidade entre os *pixels*.
- O processo de criação manual de provas para a análise quantitativa dos resultados, apresenta um problema quanto às regiões de sobreposição de tintas. Como estas

informações representam um terceiro tipo de informação, propõem-se a realização de testes considerando estas regiões como uma terceira classe para análise pelo classificador.

7 Referências Bibliográficas

- [Abu89] ABUTALEB, A. S. *Automatic Thresholding of Gray-Level Pictures Using Two Dimensional Entropy*. *Computer Graphics & Image Processing*, 47(1), 1989, p. 22-32.
- [Ala03] ALACRON. *Real-Time Fruit Inspection*. Disponível em: <http://www.alacron.com>. Acesso em: 10 jun. 2003.
- [All98] ALLTECH Associates Inc. *TLC Ink Separation Kit – A Quick & Easy Introduction To Thin Layer Chromatography (TLC)*. Disponível em: <http://www.alltechweb.com/productinfo/technical/datasheets/u7650.pdf>. Acesso em: 10 jun. 2005.
- [BBF⁺97] BRITTO JR, A. S.; BORGES, D. L.; FACON, J.; MORAES, R. S. *Técnica Interativa de Segmentação por Cor: aplicação à quantificação da mucina (muco intestinal)*. **XVII Congresso da Sociedade Brasileira de Computação**, Brasília, 1997.
- [BCS98] BORSOTTI, M.; CAMPADELLI, P.; SCHETTINI, R. *Quantitative Evaluation of Color Image Segmentation Results*. **Pattern Recognition Letters**, Vol. 19, No. 8, 1998, p. 741-48.
- [Bel98] BELONGIE S. *Color and Texture Based Image Segmentation Using EM and its Application to Content-based Image Retrieval*. **Proc. ICCV**, 1998, p. 675-82.
- [BVS02] BARBEAU, J.; VIGNES-LEBBE, R.; STAMON, G. *A Signature Based on Delaunay Graph and Co-occurrence Matrix*. **In Proceedings of the ICCVG'2002**, Pologne, 2002, p. 1-8.
- [Can86] CANNY, J. F. *A Computational Approach to Edge Detection*. **IEEE Trans. on PAMI**, Vol. 8, No. 6, 1986, p. 679-698.

- [Cas96] CASTLEMAN, K. R. *Digital Image Processing*. Prentice-Hall, New Jersey, 1996, 667 p.
- [CIE04] CIE - *Commission Internationale de l'Eclairage*. Disponível em: <http://www.cie.co.at/cie>. Acesso em: 06 jan. 2004.
- [Cio03] CIOLA, R. *Fundamentos da Cromatografia Líquida de Alto Desempenho*. Edgard Blücher, 2003.
- [Col04] COLOURWARE. *Frequently Asked Questions About Colour Physics*. Disponível em: <http://www.colourware.co.uk>. Acesso em: 05 jan. 2004.
- [Com03] COMPUTER GRAPHICS SS 2003. *Measuring Color*. Disponível em: http://www.panimex.de/MeinWeb/lect/ch08/gra11_3.html. Acesso em: 22 jun. 2005.
- [Con03] CONTROLE NET. *Tutorial sobre Vídeo Digital e Câmera Digital*. Disponível em: http://controle.net/suporte/suporte_foto_digital.shtml. Acesso em: 15 out. 2003.
- [CP95] COCQUEREZ, J. P.; PHILIPP, S. *Analyse d'Images: Filtrage et Segmentation*. Masson, Paris, 1995, p. 256-257.
- [CPM⁺02] CHEN, J.; PAPPAS, T.; MOJSILOVIC, A.; ROGOWITZ, B. *Adaptive Image Segmentation Based On Color And Texture*. **Proc. Int. Conf. Image Processing**, Rochester, New York, 2002.
- [DCV98] DEGANI, A. L. G.; CASS, Q. B.; VIEIRA, P. C. *Química Nova na Escola - Cromatografia um Breve Ensaio*. Disponível em: <http://sbqensino.foco.fae.ufmg.br/uploads/505/actual.pdf>. Acesso em: 18 mai. 2005.
- [Del97] DELIGNON, Y. *Estimation of Generalized Mixtures and its Application in Image Segmentation*. **IEEE Trans. on Image Processing**, Vol. 6, No. 10, 1997, p. 1364-76.

- [Den05] DENELSON. *Image:Yuv.png. UV colour plane, at a Y value of 0.5, mapped to RGB.* Royston, British Columbia. Disponível em: <http://en.wikipedia.org/wiki/Image:Yuv.png>. Acesso em: 29 jun. 2005.
- [DJ93] DUBUISSON, M.; JAIN, A. K. *Object Contour Extracting Using Color and Motion.* **IEEE Conference on Computer Vision and Pattern Recognition**, Nova York, 1993, p. 471–476.
- [DKM⁺99] DENG, Y.; KENNEY, C.; MOORE, M. S.; MANJUNATH, B. S. *Peer Group Filtering and Perceptual Color Image Quantization.* **Proc. ISCAS**, 1999.
- [DM90] DARKEN, C.; MOODY, J. *Fast Adaptive K-Means Clustering: Some Empirical Results.* **Int. Joint Conf. on Neural Networks**, 1990, p. 233-238.
- [DM92] DARKEN, C.; MOODY, J. *Towards Fast Stochastic Gradient Search.* **In: Advance in neural information processing systems 4**, Moody, J. E., Hanson, S. J., Lippmann, R. P. (eds.), Morgan Kaufmann, San Mateo, 1992.
- [DM99] DENG, Y.; MANJUNATH, B. S.. *JSEG - Segmentation of Color-Texture Regions in Images and Video.* Disponível em: <http://vision.ece.ucsb.edu/segmentation/jseg>. Acesso em: 12 jun. 2005.
- [DMS99] DENG, Y.; MANJUNATH, B. S.; SHIN, H. *Color Image Segmentation.* **IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR'99**, Fort Collins, CO, Vol. 2, 1999, p. 446-51.
- [DPA00] DORKÓ, G.; PAULUS, D.; AHLRICHS, U. *Color Segmentation For Scene Exploration.* **Workshop Farbbildverarbeitung**, 2000.
- [Eas05] EASYRGB. *EasyRGB.com.* Disponível em: <http://www.easyrgb.com>. Acesso em: 12 mai. 2005.

- [Efg05] EFG'S COMPUTER LAB. *HistoStrechGrays Lab Report*. Disponível em: <http://www.efg2.com/Lab/ImageProcessing/HistoStretchGrays.htm>. Acesso em: 12 mai. 2005.
- [Fab94] FABER, V. *Clustering and the Continuous K-Means Algorithm*. Disponível em: http://www.c3.lanl.gov/~kelly/ml/pubs/1994_concept/sidebar.pdf. Acesso em: 16 mai. 2005.
- [Fac96] FACON, J. *Morfologia Matemática: Teoria e Exemplos*. Editora Universitária Champagnat, Curitiba, 1996, 304 p.
- [FBI05] FBI – Federal Bureau of Investigation – Laboratory. *Questioned Documents Unit*. Disponível em: <http://www.fbi.gov/hq/lab/org/qdu.htm>. Acesso em: 17 mai. 2005.
- [FF03] FOSTER & FREEMAN. *VSC 2000/HR - Hight Resolution Video Spectral Comparator*. Disponível em: <http://www.fosterfreeman.co.uk>. Acesso em: 02 jun. 2003.
- [Fil01] FILBY, A. G. *Questioned Documents (Handwriting) Evidence*. **13th INTERPOL Forensic Science Symposium**, Lyon, France, 2001.
- [Fri03] FRIED, R. B. *Digital Photography: An In Depth Analysis of an Emerging Trend within the Computer Age*. Disponível em: <http://www.crime-scene-investigator.net/digitalphotography-fried.html>. Acesso em: 12 out. 2003.
- [GW00] GONZALEZ, R. C.; WOODS, R. E. *Processamento de Imagens Digitais*. Edgard Blücher, São Paulo, 2000, 509 p.
- [Har03] HARAN, I. *Color and the Human Response to Light*. Disponível em: <http://www.cs.tau.ac.il/~haranidi/presentations/color.ppt>. Acesso em: 17 jan. 2005.
- [Hay01] HAYKIN, S. *Redes Neurais - Princípios e Práticas*. Bookman, 2.ed, Porto Alegre, 2001.

- [Int05] INTERPOL - The International Criminal Police Organization. *Forensic*. Disponível em: <http://www.interpol.int/Public/Forensic/Default.asp>. Acesso em: 17 mai. 2005.
- [IS03] IHLOW, A.; SEIFFERT, U. *Microscope Color Image Segmentation for Resistance Analysis of Barley Cells against Powdery Mildew*. **Proc. 9th Workshop 'Farbbildverarbeitung'**, Esslingen, Germany, 2003, p. 59-66.
- [IS86] ISMAIL, M. A.; SELIM, S. Z. *Fuzzy C-Means: Optimality of Solutions and Effective Termination of the Algorithm*. *Pattern Recognition*, 19, 1986, p. 481-485.
- [JBR97] JAWAHAR, C. V.; BISWAS, P. K.; RAY, K. *Investigations On Fuzzy Thresholding Based On Fuzzy Clustering*. *Pattern Recognition*, Vol. 30, No. 10, 1997, p. 1605-1613.
- [Jus00] JUSTINO, E. J. R. *A Análise de Documentos Questionados*. Monografia para concurso de professor titular, Pontifícia Universidade Católica do Paraná, Brasil, 2000.
- [Jus01] JUSTINO, E. J. R. *O Grafismo e os métodos escondidos de Markov na Verificação Automática de Assinaturas*. Tese de Doutorado, Pontifícia Universidade Católica do Paraná, Brasil, 2001.
- [Jus99] JUSTINO, E. J. R. *Reconhecimento de Assinaturas Manuscritas Integrado a um Sistema Multiagentes – Aplicação: Autenticação de Assinaturas em Cheques Bancários Brasileiros*. Exame de Qualificação, Pontifícia Universidade Católica do Paraná, Brasil, 1999.
- [Kap03] KAPPA OPTO-ELETRONICS INC. *Digital Multispectral System - DPS 3*. Disponível em: <http://www.kappa-vision.com>. Acesso em: 01 jun. 2003.
- [KS94] KAMEL, M.S.; SELIM, S.Z. *New Algorithms for Solving the Fuzzy Clustering Problem*. *Pattern Recognition*, 27(3), 1994, p. 421-428.
- [LG03] LAMBERT, P.; GRECU, H. *A Quick And Coarse Color Image Segmentation*. **International Conference on Image Processing, ICIP**, Barcelona, 2003, p. 965-968.

- [Llo82] LLOYD, S. P. *Least Squares Quantization in PCM*. Unpublished Bell Laboratories Technical Note. **IEEE Trans. Information Theory**, 1982.
- [Luk05] LUKE, B. T. *K-Means Clustering*. Disponível em: <http://fconyx.ncifcrf.gov/~lukeb/kmeans.html>. Acesso em: 16 mai. 2005.
- [LWZ03] LEE, J.; WANG, J.; ZHANG, C. *Color Image Segmentation: Kernel Do the Feature Space*. **The 14th European Conference on Machine Learning**, Cavtat, Croatia, 2003.
- [Mac67] MACQUEEN, J. *Some methods for classification and analysis of multivariate observations*. **Proc. of the Fifth Berkeley Symp. on Math., Statistics and Probability**, LeCam, L. M., and Neyman, J., (eds.), Berkeley: U. California Press, Vol. 1, 1967, p. 281-296.
- [Mai03] MAI, L. C.. *Computer Vision, Imaging - Introduction to Computer Vision and Image Processing - Color Representation*. Disponível em: <http://www.netnam.vn/unescocourse/computervision/12.htm>. Acesso em: 20 out. 2003.
- [Mas98] MASHOR, M. Y. *Improving the Performance of K-Means Clustering Algorithm to Position the Centres of RBF Network*. **International Journal Of Computer, The Internet And Management**. Vol. 6, No. 2, 1998.
- [Mat05] MATTEUCCI, M. *A Tutorial on Clustering Algorithms*. Disponível em: http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial_html. Acesso em: 16 mai. 2005.
- [Mel03] MELLES GRIOT. *Omniprint 1000A - Forensic Light Source*. Disponível em: <http://www.mellesgriot.com>. Acesso em: 02 jun. 2003.
- [Men03] MENDES, L. B. *Documentoscopia*. Millennium, 2 ed. Campinas, 2003, 344 p., (Tratado de Perícias Criminalísticas, 7).

- [Mic04] MICRONAL. *Boletim de Aplicação - Dicas em Cromatografia Planar*. Micronal - Precisão em Soluções. Disponível em: http://www.micronal.com.br/artigostecnicos/dicas_cromatografiaPlanar_jun2004.htm. Acesso em: 20 jun. 2005.
- [MM97] MA, W.Y.; MANJUNATH, B. S. *Edge Flow: A Framework of Boundary Detection and Image Segmentation*. **Proc. of CVPR**, 1997, p. 744-49.
- [MPG04] MARTÍNEZ-USÓ A.; PLA F.; GARCÍA-SEVILLA P. *A Novel Energy Minimization Criterion for Color Image Segmentation*. **International Conference on Patern Recognition, ICPR'04**, Cambridge, Vol. 3, 2004, p. 206-209.
- [Nor05] NORWITCH, F. H. *Alteration / Obliteration & Ink Examinations*. Norwich Document Laboratory, Florida. Disponível em: <http://www.questioneddocuments.com/Question%20Doc%20Overviews/Alteration&Obliteration/alteration&obliteration.html>. Acesso em: 10 jun. 2005.
- [Oly03] OLYMPUS. *Site Oficial Olympus da America Latina*. Disponível em: <http://www.olympusamerica.com>. Acesso em: 10 jul. 2003.
- [Ots79] OTSU, N. *A Threshold Selection Method from Gray-level Histograms*. **IEEE Transactions on Systems, Man and Cybernetics**, No 1, 1979, p. 62-66.
- [Par96] PARKER, J. R. *Algorithms for Image Processing and Computer Vision*. John Wiley e Sons, 1996, p. 145-148.
- [PH95] PANJWANI, D. K.; HEALEY, G. *Markov Random Field Models for Unsupervised Segmentation of Textured Color Images*. **PAMI**, Vol. 17, No. 10, 1995, p. 939-54.
- [Pun81] PUN, T. *Entropic Thresholding, the new Approach*. *Computer Graphics and Image Processing*, Vol.16, 1981, p 210-239.

- [Ras94] RASHA, A. *A Prototype System for Off-Line Signature Verification Using Multilayered Feedforward Neural Networks*. Dissertação de Mestrado, RMIT Department of Computer Science, Melbourne, 1994.
- [RB95] REHRMANN, V.; BIRKHOFF, M.. *Echtzeitfähige Objektverfolgung in Farbbildern*. **Erster Workshop Farbbildverarbeitung**, Fachberichte Informatik, Vol. 15, 1995, p. 13–16.
- [RW96] RITTER, G. X.; WILSON, J. N. *Handbook of Computer Vision Algorithms in Image Algebra*, CRC Press., Florida, 1996.
- [San04] SANTOS, C. R. *Análise de Assinaturas Manuscritas Baseada nos Princípios da Grafoscopia*. Dissertação de Mestrado, Pontifícia Universidade Católica do Paraná, Brasil, 2004.
- [Ski05] SKILJAN, I.. *Irfan View - One of the Most Popular Viewers Worldwide!*. Austria, Europa. Disponível em: <http://www.irfanview.com>. Acesso em: 20 mar. 2005.
- [SKM04] SUMENGEN, B.; KENNEY, C.; MANJUNATH, B. S. *Variational Image Segmentation using Color and Texture*. Disponível em: <http://vision.ece.ucsb.edu/segmentation/variational2>. Acesso em: 10 jan. 2005.
- [SM97] SHI, J.; MALIK, J. *Normalized Cuts and Image Segmentation*. **Proc. of CVPR**, 1997, p. 731-37.
- [SMP04] SMPTE. *Society of Motion Picture and Television Engineers*. Disponível em: <http://www.smpte.org>. Acesso em: 10 jan. 2004.
- [Sob03] SOBRAL, J. L. *Visão por Computador - Processamento de Imagens a Cores*. Disponível em: <http://gec.di.uminho.pt/lesi/vpc0203/Aula04Cor.pdf>. Acesso em: 20 out. 2003.

- [SPK97] SHAFARENKO, L.; PETROU, M.; KITTLER, J. *Automatic Watershed Segmentation of Randomly Textured Color Images*. **IEEE Trans. on Image Processing**, Vol. 6, No. 11, 1997, p. 1530-44.
- [Tek04] TEKNOMO, K. *K-Means Clustering Tutorials*. Disponível em: <http://people.revoledu.com/kardi/tutorial/kMean/index.html>. Acesso em: 16 mai. 2005.
- [TG74] TOU, J. T.; GONZALEZ, R. C. *Pattern Recognition Principles*. Addison-Wesley, Reading, MA, 1974, 178 p.
- [TO98] TSUTSUMI, K.; OHGA, K. *Analysis Of Writing Ink Dyestuffs By TLC And FT-IR And Its Application To Forensic Science*. **Analytical Sciences - The Japan Society for Analytical Chemistry**, Vol.14, 1998.
- [Wal04] WALKER, J. *Colour Rendering of Spectra*. Disponível em: <http://www.fourmilab.ch/documents/specrend>. Acesso em: 10 jan. 2004.
- [Wan98] WANG, J. P. *Stochastic Relaxation on Partitions with Connected Components and its Application to Image Segmentation*. **PAMI**, Vol. 20, No.6, 1998, p. 619-36.
- [Wes05] WEISSTEIN, E. W. *MathWorld - A Wolfram Web Resource - K-Means Clustering Algorithm*. Disponível em: <http://mathworld.wolfram.com/K-MeansClusteringAlgorithm.html>. Acesso em: 16 mai. 2005.
- [XKO93] XU, L.; KRZYZAK, A.; OJA, E. *Rival Penalised Competitive Learning for Clustering Analysis, RBF Net and Curve Detection*. **IEEE Trans. on Neural Networks**, 4(4), 1993.
- [Yan96] YAN, H. *Unified Formulation of a Class of Image Thresholding Techniques*. *Pattern Recognition*, Vol. 29, No. 12, 1996, p. 2025-2032.
- [Zha05] ZHANG, H. *Biyee - Color Vision - 1931 CIE Diagrams*. Disponível em: http://www.biyee.net/v/cie_diagrams. Acesso em: 20 jan. 2005.

[ZW00] ZHANG, C.; WANG, P. *A New Method of Color Image Segmentation Based on Intensity and Hue Clustering*. **Proc. 15th International Conference on Pattern Recognition**, Barcelona, Spain, 2000, p. 3617-3620.

[ZY96] ZHU, S. C.; YUILLE, A. *Region Competition: Unifying Snakes, Region Growing, And Bayes / MDL For Multiband Image Segmentation*. **PAMI**, Vol. 18, No. 9, 1996, p. 884-900.

Apêndice A

A Documento do Processo de Aquisição

Este apêndice contém o conteúdo na íntegra do “Documento do Processo de Aquisição” porém com sua formatação alterada para os moldes deste documento de dissertação.

A.1. Introdução

Para a aquisição de uma amostra completa é necessário submeter esta a diversos tipos de situações, configuradas através de diferentes tipos de lentes, diferentes distâncias de lentes e da câmera, entre outros. Estas situações, bem como os equipamentos utilizados, são enunciadas neste documento para que todas as aquisições de amostras sejam compatíveis entre si e para que o processo de aquisição seja facilmente absorvido e/ou reproduzido por leitores deste trabalho.

A.2. Equipamentos Utilizados

Este trabalho utiliza diversos tipos de equipamentos para a obtenção de amostras. No decorrer desta seção serão descritas as combinações de equipamentos para a obtenção destas.

A.2.1. Câmera Digital

Visando um processo de aquisição de imagens rápido e com baixo custo este trabalho utiliza uma câmera fotográfica digital. A descrição técnica relevante da câmera utilizada neste trabalho é a seguinte:

- **Fabricante:** Olympus
- **Tipo da Câmera:** Digital
- **Identificação:** CAMEDIA C-720 Ultra Zoom
- **Resolução:** 640x480 (SQ2) à 1984x1488 (TIFF / SHQ / HQ)
- **Lente:** Olympus de 6,4mm à 51,2mm (equivalente a 40mm até 320mm em câmeras de 35mm)
- **Sensor:** CCD *solid-state* de 1/2,25 polegadas

A.2.2. Lentes Adicionais

Com o uso de um adaptador próprio da Olympus de 45.6mm para 55mm, pode-se utilizar lentes adicionais. As lentes adicionais utilizadas por neste trabalho são descritas na Tabela A.1:

Tabela A.1: Descrição de lentes adicionais utilizadas

Fabricante	Tamanho	Modelo
S & K	55 mm	Close-Up +2
S & K	55 mm	Close-Up +3
S & K	55 mm	Close-Up +4

A.2.3. Iluminação de Incidência

A iluminação de incidência foi acoplada a *spots* para que sua emissão possa refletir diretamente no objeto alvo. A fonte de iluminação por incidência utilizada é constituída de uma lâmpada halógena com filamento de tungstênio. A faixa de comprimento de onda atingida por este tipo de lâmpada é de 300nm à 1000nm.

A.2.4. Canetas

Como o objeto alvo referenciado por este documento são folhas de papel com marcas de tinta originárias de canetas esferográficas. A Tabela A.2 demonstra a relação das canetas utilizadas neste trabalho.

Tabela A.2: Descrição das canetas utilizadas

Fabricante	Corante	Modelo
Pilot	Azul	BP-S 0,7 mm
Paper-Mate	Azul	Comfort-Mate
Faber Castell	Azul	Fine
Bic	Azul	D-F-9
CIS	Azul	Superball 1,2 mm
Pilot	Azul	BP-S Grip 1,0 mm
Compactor	Azul	0,7
Sum	Azul	G-0,7
Reynolds	Azul	1 mm - Medium 048
Faber Castell	Azul	Power Ball 063 Fine

A.2.5. Papel

O papel utilizado como superfície alvo para o depósito das massas corantes das canetas é descrito a seguir:

- **Fabricante:** Chamex
- **Identificação:** *Print & Copy Paper*
- **Formato:** A4
- **Tipo:** Alcalino
- **Dimensões:** 210x297 mm
- **Volume:** 75 g/m²

A.2.6. Equipamentos Adicionais

Como equipamentos adicionais para a obtenção das amostras utiliza-se um óculos próprio para proteção dos olhos. O óculos utilizado neste trabalho está descrito a seguir:

- **Fabricante:** Uvex

- **Importador:** Balaska
- **Cor:** Amarela
- **Filtragem:** mais de 99,9 % da radiação ultra-violeta

A.3. Características do Processo de Aquisição

Esta seção contém o conteúdo do “Formulário para a Base de Dados” que é parte integrante do “Documento do Processo de Aquisição”, porém com sua formatação alterada para os moldes deste documento. Este formulário apresenta as informações relevantes sobre as configurações para o processo de aquisição, conforme as sub-seções a seguir.

A.3.1. Equipamento de Aquisição

- **Modo de Operação da Câmera:** Automático
- **Uso de Timer:** Não
- **Abertura e Velocidade:** Automáticas
- **Distância entre última lente e o documento:** 7,6 cm
- **Distância entre a base e o pedestal da câmera:** 13,3 cm
- **Uso de Zoom Analógico:** Sim
- **Uso de Zoom Digital:** Não

A.3.2. Equipamento de Iluminação

- **Por incidência ou por transferência:** Incidência
- **Tipo de luz:** Halógena com filamento de tungstênio
- **Quantidade de fontes luminosas:** 2
- **Distância entre a base e o pedestal da fonte:** 0 cm
- **Distância entre a fonte e o centro do documento:** 12,5 cm

A.3.3. Lentes Adicionais

- **Quantidade de lentes: 3**
- **Modelo da Lente 1: S & K, Close-Up +2, 55 mm**
- **Modelo da Lente 2: S & K, Close-Up +3, 55 mm**
- **Modelo da Lente 3: S & K, Close-Up +4, 55 mm**