



Pós-Graduação em Ciência da Computação

Fabiane da Silva Queiroz

RESTAURAÇÃO DE IMAGENS ATRAVÉS DE REFLEXOS ESPECULARES



Universidade Federal de Pernambuco

posgraduacao@cin.ufpe.br

<http://cin.ufpe.br/~posgraduacao>

RECIFE

2017

Fabiane da Silva Queiroz

RESTAURAÇÃO DE IMAGENS ATRAVÉS DE REFLEXOS ESPECULARES

Este trabalho foi apresentado à Pós-Graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Doutor em Ciência da Computação.

ORIENTADOR(A): Prof. Tsang Ing Ren

RECIFE
2017

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

Q3r Queiroz, Fabiane da Silva
Restauração de imagens através de reflexos especulares/ Fabiane da Silva
Queiroz. – 2017.
119 f.: il., fig., tab.

Orientador: Tsang Ing Ren.
Tese (Doutorado) – Universidade Federal de Pernambuco. CIn, Ciência da
Computação, Recife, 2017.
Inclui referências.

1. Inteligência artificial. 2. Processamento de imagem. I. Ren, Tsang Ing
(orientador). II. Título.

006.3 CDD (23. ed.) UFPE- MEI 2017-126

Fabiane da Silva Queiroz

Restauração de Imagens Através de Reflexos Especulares

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutora em Ciência da Computação

Aprovado em: 10/02/2017.

Orientador: Prof. Dr. Tsang Ing Ren

BANCA EXAMINADORA

Prof. Dr. George Darmiton da Cunha Cavalcanti
Centro de Informática / UFPE

Prof. Dr. Paulo Salgado Gomes de Mattos Neto
Centro de Informática / UFPE

Prof. Dr. Alejandro César Frery Orgambide
Instituto de Computação / UFAL

Prof. Dr. Renato José de Sobral Cintra
Departamento de Estatística / UFPE

Prof. Dr. Jorge de Jesus Gomes Leandro
Motorola Mobility LLC

Aos meus amados pais, Raimundo e Francinete, que me permitiram sonhar, persistir e alcançar. A vocês dedicarei todas as minhas conquistas, sempre.

Agradecimentos

Aos meus pais, que serão sempre o motor de todas as minhas conquistas. A Jhone, meu par, por sua paciência, prestatividade e por todas as palavras de encorajamento nesse percurso. A Tsang, meu orientador, por ter acreditado no meu potencial acadêmico e pelas críticas que conduziram minha evolução enquanto pesquisadora. Aos meus colegas de trabalho (nobres correligionários), que me proporcionaram aquele ano de afastamento que muito me ajudou na finalização dos créditos requeridos neste doutorado. A Universidade Federal de Alagoas, que me concedeu bolsa de auxílio à capacitação docente durante meu período de afastamento. Aos meus alunos, orientandos de TCC e projetos de extensão na UFAL, pela compreensão em lidar com os momentos em que estive ausente. Aos meus amigos queridos, cuja amizade e *good vibe* tornam todos os meus dias mais leves. Em especial, a Edileuza, que me acompanhou em muitas viagens cansativas para Recife e cuja companhia tornava a viagem divertida e animada. A Rosamaria, minha irmã, pelo teto em Recife, pelo carinho e pelas horas prazerosas de conversa. A Jorge Amado, Gabriel Garcia Marques, José Saramago, dentre outros literatas, cujas obras me permitiram (e ainda permitem) emergir do universo acadêmico e mergulhar em universos de muitos encantos e reduções à essência do que somos nós. A Céu, que me mostrou que apesar de subir o rio no contra-fluxo à margem da loucura, podemos nos deixar levar pela leveza ir na bubuia. Suas canções tiveram o poder de me acalmar nos momentos de maior exaustão da pós graduação. Por fim, a todos que tiveram seu caminho cruzado com o meu, e dessa forma contribuíram direta ou indiretamente na construção deste trabalho, o meu muitíssimo obrigada.

*“We are all mad here.”
(Mad Hatter)*

Resumo

A restauração cega de imagens corrompidas por borramento é um problema inverso clássico da área de Processamento de Imagens e Visão Computacional. Um processo de restauração de imagens é definido como cego, quando desconhecemos tanto a imagem original não corrompida quanto a Função de Espalhamento de Ponto da degradação (PSF - *Point Spread Function*) e o ruído envolvido neste processo. Imagens de endoscopia óptica são comumente afetadas por borramento devido à movimentação da câmera no processo de captura ou a movimentos involuntários da superfície do tecido do trato gastrointestinal. Nesta tese propomos um novo método de restauração cega de imagens de endoscopia óptica. Para tanto, nós exploramos o uso de reflexos especulares, que constituem outro tipo de degradação muito comum nesse tipo de imagem, e que por sua vez, são utilizados como informação *a priori* no processo de estimativa da PSF do borramento. Sendo assim, o método aqui proposto pode ser dividido em duas etapas. A primeira etapa consiste de um novo método de segmentação precisa de reflexos especulares que podem, por sua vez, conter ricas informações sobre a degradação sofrida pela imagem. A segunda etapa consiste de um novo método de estimação da PSF da degradação, no qual a mesma é inferida através do agrupamento e fusão dos reflexos segmentados previamente. Observamos que a fusão de reflexos especulares não fere os pré-requisitos de que a PSF estimada deve ser esparsa, positiva e com um tamanho pequeno quando comparado ao tamanho da imagem sendo restaurada. Além disso, uma vez que sabemos que tais reflexos podem conter informações relevantes do processo de borramento, mostramos que quando fundidos, estes podem ser utilizados na estimação da PSF do borramento, produzindo assim resultados satisfatórios de imagens restauradas quando estas são comparadas à imagens restauradas por métodos do estado da arte, sendo a qualidade das imagens restauradas pelo método aqui proposto muitas vezes superior ou equivalente aos trabalhos comparados.

Palavras-chave: Processamento de Imagens. Segmentação de Reflexos Especulares. Borramento Invariante no Espaço. Restauração de Imagens. Deconvolução Cega.

Abstract

Blind image deconvolution (blind image deblurring or blind image restoration) is a classical inverse problem of Image Processing and Computer Vision. In a blind deconvolution process, the original uncorrupted image and the Point Spread Function (PSF) of the degradation are unknown. Images of optic endoscopy are commonly affected by blur due camera movements during the image capture process or due involuntary movements of the gastrointestinal tissue. In this work, we propose a new blind deconvolution method of optical endoscopy blurred images. We explore the use of specular reflections that are a very common degradation in this type of images. These reflections are used as a prior information to the PSF estimation process. The proposed method can be divided into two stages. The first stage consists of a new method to perform a precise segmentation of specular reflections. The second step consists of a new estimation method of the PSF. This PSF is inferred by grouping and fusion of specular reflections previously segmented. We observed that the proposed method of fusion of these reflections meets the prerequisites that the estimated PSF must be sparse, positive and have a small size when compared with the blurred image size. Also, since we know that these reflections may contain relevant information about the degradation, we show that when fused, they may be used in the estimation of the PSF producing satisfactory results where, in many cases, the quality of the images restored by the proposed method is superior or equal to the images restored by other state-of-the-art methods.

Keywords: Image Processing. Specular Reflections Segmentation. Space Invariant Deblurring. Image Restoration. Blind image deconvolution.

Lista de ilustrações

Figura 1 – Estrutura de uma fibra óptica.	20
Figura 2 – Ilustrações de procedimentos endoscópicos, o endoscópio e imagem obtida com um endoscópio.	21
Figura 3 – Exemplo de cápsula endoscópica.	21
Figura 4 – Imagens de endoscopia óptica apresentando <i>highlights</i> e regiões borradas.	23
Figura 5 – Reflexão especular de um raio de luz sobre uma superfície lisa e polida	27
Figura 6 – Exemplos de imagens que contêm reflexos especulares ou pequenos pontos de luz.	28
Figura 7 – Exemplo de borramento por movimentação de câmera ideal	33
Figura 8 – Movimentação complexa de uma câmera	34
Figura 9 – Degradação causada por movimentação de câmera	34
Figura 10 – Borramento causado por falta de foco	35
Figura 11 – Cena dinâmica	36
Figura 12 – Exemplos comuns de PSF.	37
Figura 13 – Deconvolução cega de imagens vista como um problema inverso severamente mal posto.	39
Figura 14 – Contexto Bayesiano de estimação.	41
Figura 15 – Termos <i>a priori</i> para a imagem nítida I	43
Figura 16 – Resultados da aplicação do algoritmo <i>alpha matting</i> em duas imagens distintas.	48
Figura 17 – Mais imagens de endoscopia óptica apresentando reflexos especulares.	51
Figura 18 – Segmentação grosseira e precisa de reflexos especulares em imagens de endoscopia Óptica	52
Figura 19 – Fluxograma representando o esquema de segmentação de reflexos especulares em imagens de endoscopia óptica.	54
Figura 20 – Realce de reflexos especulares em uma imagem de endoscopia óptica.	55
Figura 21 – Componente esparso E resultante da decomposição matricial utilizando RPCA.	57
Figura 22 – Histograma do componente esparso E . A linha tracejada em vermelho se refere ao valor de $s(E)$	58
Figura 23 – Definição da componente esparsa E_{final}	60
Figura 24 – Alguns resultados do método proposto de segmentação de reflexos especulares em imagens de endoscopia óptica.	60
Figura 25 – Perfil 1-D de um sinal borrado.	63
Figura 26 – Continuação das ilustrações da Figura 25	65

Figura 27 – Fluxograma representando o esquema proposto de restauração de imagens endoscópicas.	67
Figura 28 – Características extraídas dos reflexos especulares presentes na componente especular E	68
Figura 29 – Reflexos especulares com formas semelhantes possuem assinaturas semelhantes	69
Figura 30 – Região com forma irregular e seu casco convexo.	69
Figura 31 – Ilustrações dos descritores f_{MA} e f_O de uma região.	70
Figura 32 – Ilustração gráfica do agrupamento proposto sobre uma imagem contendo $n = 18$ reflexos especulares após repetidas execuções do FCM.	73
Figura 33 – Imagem degradada e sua PSF de degradação.	73
Figura 34 – Gráfico de dispersão bivariada das seis características extraídas de cada elemento i referente a cada reflexos especular na imagem.	74
Figura 35 – <i>Highlights</i> agrupados.	75
Figura 36 – Sequência de PSFs estimadas dentro dessa abordagem multi-escala.	79
Figura 37 – Método comum de restauração usando a abordagem multi-escala.	80
Figura 38 – Método de restauração proposto	82
Figura 39 – Fusão de reflexos especulares para geração de PSFs em potencial e estimação da PSF da degradação.	82
Figura 40 – Resultados do processo de restauração de imagens endoscópicas com base no agrupamento e fusão de reflexos especulares.	83
Figura 41 – Exemplos de Imagens da Base <i>CVC-ColonDB</i>	85
Figura 42 – Rotulação de reflexos especulares para a geração do <i>ground truth</i>	86
Figura 43 – Imagem original colorida e sua componente difusa.	86
Figura 44 – Análise de variância para avaliar a similaridades entre as amostras contendo os coeficientes de <i>Jaccard</i>	89
Figura 45 – Resultados comparativos do método de segmentação.	90
Figura 46 – Resultados comparativos do método de segmentação.	90
Figura 47 – (a) Imagem Original sem os reflexos especulares; (b) Componente difusa resultante do método proposto sem os reflexos especulares; (c) Componente difusa resultante método proposto por Chwyl et al. (2015) sem os reflexos especulares; (d) <i>Zoom</i> sobre as componentes difusas.	91
Figura 48 – Análise de variância para avaliar a similaridades entre as amostras contendo os valores para o index SSIM.	92
Figura 49 – Resultados comparativos do método de segmentação.	93
Figura 50 – Remoção e preenchimento de regiões de reflexos especulares em imagens endoscópicas.	95
Figura 51 – PSFs utilizadas na degradação das imagens do experimento	96
Figura 52 – Resultados comparativos dos métodos de restauração de imagens.	99

Figura 53 – Análise de variância para avaliar a similaridades entre as amostras contendo os valores da métrica PV.	100
Figura 54 – Análise de variância para avaliar a similaridades entre as amostras contendo os valores da métrica PV.	101
Figura 55 – Gráfico de frequência acumulada para a detecção de pólipos nas imagens originais, degradadas e restauradas.	106
Figura 56 – Limitações do método de restauração proposto.	109

Lista de tabelas

Tabela 1 – Teste de normalidade sobre as amostras contendo os coeficientes de <i>Jaccard</i>	88
Tabela 2 – Tempos de processamento dos métodos de segmentação de reflexos especulares comparados.	94
Tabela 3 – Teste de normalidade sobre as amostras contendo os valores para a métrica PV.	97
Tabela 4 – Tempos de processamento para os métodos comparados de restauração de imagens.	103
Tabela 5 – Tempos de processamento para cada uma das etapas do método de restauração proposto.	104

Lista de abreviaturas e siglas

CRF	Camera Response Function
CT	Computed Tomography
DCT	Discrete Cosine Transform
DOF	Depth Of Field
FCM	<i>Fuzzy C-Means</i>
GMM	Gaussian Mixture Model
INCA	Instituto Nacional do Câncer
MAP	<i>Maximum A Posteriori</i>
MRF	Markov Random Fields
MRI	Magnetic Resonance Imaging
PCA	Principal Component Analysis
PSF	Point Spread Function
PSNR	Métrica <i>Peak Signal-to-Noise Ratio</i>
PV	Métrica (<i>Perceptually-Validated</i>)
RPCA	Robust PCA
SSIM	Métrica <i>Structural SIMilarity</i>
SVM	Support Vector Machine
VBM	Variational Bayes Model

Lista de símbolos

B	Imagem borrada
I	Imagem nítida original
k	PSF do sistema de degradação
η	Ruído gaussiano branco
D_{rgb}	Imagem de endoscopia ótica colorida realçada
E	Componente especular de uma imagem
E_{sparse}	Versão mais esparsa da componente especular de uma imagem
A	Componente <i>low-rank</i> de uma imagem
θ_i	Ângulo de incidência de um raio em uma superfície
θ_r	Ângulo de reflexão de um raio em uma superfície
θ_{xyz}	Vetor que contém os ângulos de empinamento, cabeceio e balanceio de uma câmera, respectivamente
\mathbf{x}	Vetor de coordenadas espaciais de um pixel de uma imagem
\mathbb{R}	Conjunto de regiões binárias disjuntas referentes aos highlights em E
\mathbb{E}	Conjunto dos fragmentos de E equivalentes a cada região $R_i \in \mathbb{R}$
M	Magnitude do gradiente de D_{rgb}
$\mathbb{M}^{\mathbb{R}}$	Conjunto dos fragmentos em M referente a cada região $R_i \in \mathbb{R}$
$\delta_{(p,q)}(x, y)$	Função <i>Delta de Dirac</i>
h	<i>Highlight</i> presente em um sinal
B_h	Sinal borrado contendo um <i>highlight</i>
I_h	Sinal nítido contendo um <i>highlight</i>
B_{-h}	Sinal borrado que não contém <i>highlight</i>
I_{-h}	Sinal nítido que não contém <i>highlight</i>
f_{DC}	Componente DC da DCT aplicada a um elemento $R_i \in \mathbb{R}$

f_E	Densidade espectral da assinatura A_i de um elemento $R_i \in \mathbb{R}$
f_{CA}	Área convexa de um elemento $R_i \in \mathbb{R}$
f_{MA}	Comprimento do maior eixo da elipse que engloba um elemento $R_i \in \mathbb{R}$
f_O	Ângulo entre o eixo da elipse que engloba um elemento $R_i \in \mathbb{R}$ e o eixo horizontal
f_η	Entropia calculada para um elemento $E^{R_i} \in \mathbb{E}^{\mathbb{R}}$
F	Conjunto de características f extraídas de todos os <i>highlights</i> em E
C	Conjunto de grupos de <i>highlights</i>
P	Conjunto de PSFs em potencial resultante da combinação de <i>highlights</i>
B	Conjunto dos fragmentos da imagem borrada B que contêm regiões de <i>highlight</i>
$\rho(X, Y)$	Coefficiente de correlação de Pearson entre duas variáveis aleatórias X e Y

Sumário

1	INTRODUÇÃO	18
1.1	Imagens de Endoscopia Óptica	20
1.1.1	Degradações Comuns em Imagens de Endoscopia Óptica	22
1.2	Hipóteses	23
1.3	Objetivos	24
1.4	Contribuições	25
1.5	Organização do Texto	25
2	FUNDAMENTAÇÃO TEÓRICA E TRABALHOS RELACIONADOS	27
2.1	Reflexos Especulares e Pequenos Pontos de Luz	27
2.2	Deteccção de Reflexos Especulares em Imagens de Endoscopia Óptica	28
2.3	Formulação do Problema do Borramento de Imagens	31
2.3.1	Degradação Causada por Movimentação de Câmera	33
2.3.2	Degradação Causada por Falta de Foco	35
2.3.3	Degradação Causada por Movimentação de Objetos em Cena	36
2.3.4	PSFs de Degradação em Imagens	37
2.4	Restauração de Imagens com Borramento Invariante no Espaço	37
2.4.1	Formulação Probabilística e o <i>Framework</i> Bayesiano	38
2.4.2	Estimador Máximo <i>a Posteriori</i> - $MAP_{I,k}$	39
2.4.2.1	Regularização para a imagem nítida I	40
2.4.2.2	Regularização para a PSF k	42
2.4.2.3	Distribuição Marginal e MAP_k	44
2.5	Restauração de Imagens Utilizando <i>Highlights</i>	45
3	SEGMENTAÇÃO DE REFLEXOS ESPECULARES EM IMAGENS DE ENDOSCOPIA ÓPTICA	51
3.1	Realce de Reflexos Especulares	53
3.2	Decomposição da Imagem via RPCA	54
3.3	Segmentação dos Reflexos especulares: Definição da Componente Esparsa da Imagem	57
4	RESTAURAÇÃO DE IMAGENS ENDOSCÓPICAS UTILIZANDO REFLEXOS ESPECULARES	62
4.1	Estimação da Degradação Através de <i>Highlights</i>	62
4.2	Restauração de Imagens Endoscópicas Baseada no Agrupamento e Fusão de Reflexos Especulares	64

4.2.1	Extração de Características	66
4.2.2	Agrupamento de Reflexos Especulares	70
4.2.3	Fusão de Reflexos Especulares - Geração de PSFs em Potencial	75
4.2.4	Encontrando a Melhor PSF em Potencial	77
4.2.5	Estimação da PSF da Degradação e Restauração da Imagem	78
4.2.5.1	Restauração da Imagem	81
5	EXPERIMENTOS E RESULTADOS	84
5.1	Base de Imagens Utilizada nos Experimentos	84
5.2	Validação do Método de Segmentação de Reflexos Especulares	84
5.2.1	Parâmetros Utilizados	87
5.2.2	Métricas do Experimento e Estatísticas	87
5.2.3	Tempos de Processamento	91
5.2.4	Remoção e Preenchimento de Reflexos Especulares em Imagens Endoscópicas	93
5.3	Validação do Método de Restauração de Imagens	94
5.3.1	Parâmetros Utilizados	96
5.3.2	Métricas do Experimento e Estatísticas	96
5.3.3	Tempos de Processamento	98
5.4	Detecção Automática de Pólipos em Imagens de Colonoscopia óptica Restauradas	102
6	CONSIDERAÇÕES FINAIS	107
6.1	Contribuições	107
6.2	Limitações	108
6.3	Trabalhos Futuros	109
	REFERÊNCIAS	111

1 INTRODUÇÃO

Durante a captura de uma imagem, existem fatores intrínsecos ou extrínsecos ao seu processo de formação que podem causar degradações. Um exemplo comum de degradação em imagens é o borramento (*blur*). Do ponto de vista artístico, borramento em fotografias pode ser intencional e considerado parte da obra, porém, no geral, ele indica uma degradação indesejada, como por exemplo:

- Um carro em movimento pode aparecer borrado em uma imagem capturada por uma câmera de segurança, dificultando assim o reconhecimento de sua placa;
- Muitas vezes, quando não há um auxílio de um tripé ou outro recurso que traga estabilidade de movimentos para a câmera, é difícil para os fotógrafos estabilizarem os movimentos da mesma por um longo período de tempo, especialmente quando eles capturam fotos em condições de pouca luz, que exigem longos tempos de exposição, resultando em imagens também borradas pela movimentação da câmera;
- A maioria dos sistemas de imagens possuem apenas um foco, logo, as imagens que resultam desses sistemas acabam por vezes com regiões da imagem borradas.

Do ponto de vista de Processamento de Imagens e Visão Computacional, imagens borradas são um incômodo em uma variedade de aplicações, com por exemplo, em algoritmos de reconhecimento de faces (NISHIYAMA et al., 2011), diagnóstico médico e cirurgia (TZENG; LIU; NGUYEN, 2010), monitoramento e vigilância (VOUGIOUKAS; BOOM; FISHER, 2013) e sensoriamento remoto (MA; DIMET, 2009). Portanto, detectar e amenizar o efeito desse tipo de degradação é um passo crucial no processo de melhoria de imagens. Existem diversos métodos de restauração de imagens borradas (*image deblurring*), e este é um problema inverso clássico que busca recuperar imagens nítidas a partir de imagens degradadas por borramento e ruídos. Em geral, dentre os métodos de restauração existentes, podemos citar aqueles desenvolvidos em contextos multi-imagens (DELBRACIO; SAPIRO, 2015), via análises de irregularidades espectrais (GOLDSTEIN; FATTAL, 2012), métodos baseados em homografias (WHYTE et al., 2010) ou, de forma mais comum, assumindo-se um borramento uniforme na imagem, o processo de restauração pode ser visto como um problema de **deconvolução** (*image deconvolution*) no qual utiliza-se comumente, na solução do problema, um modelo Bayesiano (FERGUS et al., 2006; WIPF; ZHANG, 2013; PAN et al., 2016).

Em um problema típico de deconvolução de imagens, modelado pela [Equação 1.1](#), as variáveis envolvidas no processo são a imagem borrada B , a imagem nítida I a ser estimada, a função de degradação k e o ruído η (geralmente assumido como ruído gaussiano).

$$B(\mathbf{x}) = (I * k)(\mathbf{x}) + \eta(\mathbf{x}) \quad (1.1)$$

A função de degradação k , também conhecida por *kernel* de degradação ou **função de espalhamento de ponto** (*Point Spread Function* - PSF) é dita uniforme ou **invariante no espaço** quando sua resposta em qualquer ponto $\mathbf{x} = (x, y)$ da imagem depende somente do valor de entrada nesse ponto, e não de sua posição. Essa PSF k faz com que um pixel da imagem represente informação de luminosidade proveniente de vários pontos da cena, e isto ocorre devido a diversos fatores, tais como a difração de luz dada a abertura finita do obturador, falta de foco e o movimento relativo entre a câmera e a cena durante a exposição, provocando assim o efeito de borramento na imagem.

Podemos classificar os métodos de deconvolução de imagens em dois grupos de acordo com a quantidade de variáveis desconhecidas no problema da [Equação 1.1](#). Chamamos o método de **deconvolução não-cega** (*non-blind deconvolution*), quando apenas a imagem nítida I é desconhecida ([YUAN et al., 2008](#); [CHO](#); [WANG](#); [LEE, 2011](#); [SCHMIDT et al., 2013](#)), enquanto que na **deconvolução cega** (*blind deconvolution*), tanto a imagem I quanto a PSF da degradação k são desconhecidas ([FERGUS et al., 2006](#); [LEVIN et al., 2011](#); [MICHAELI](#); [IRANI, 2014](#); [PAN et al., 2016](#)).

Imagens médicas são comumente afetadas por borramentos e ruídos. Em imagens de ressonância magnética (*Magnetic Resonance Imaging* - MRI), os movimentos do paciente são a causa mais comum de degradação. Movimentos aleatórios podem produzir uma imagem embaçada e ruidosa, enquanto que movimentos periódicos criam imagens fantasmas (*ghost artifact*) na direção de codificação de fase do sinal que gera a imagem de MRI ([DEBNATH et al., 2013](#))¹. Em tomografia computadorizada (*Computed Tomography* - CT), o borramento ocorre devido a diversos fatores, tais como o tamanho finito do ponto focal da fonte de raios X, perda de dados no processo de aquisição ([AL-AMEEN](#); [SULONG, 2015](#)), radiação insuficiente ([ATTIVISSIMO et al., 2010](#)), etc. As imagens da retina são recursos clínicos essenciais para a detecção de muitas doenças oculares. Devido a condições de aquisição inadequadas ou aberrações ópticas inerentes ao olho, estas imagens também são frequentemente degradadas por borramento ([MARRUGO et al., 2011](#); [MARRUGO et al., 2014](#)).

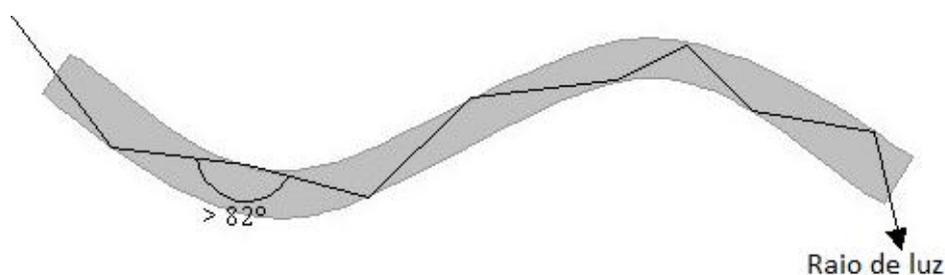
¹ São necessárias três etapas para a codificação do sinal, de forma a obter uma imagem de MRI: seleção de corte, codificação de fase e codificação de frequência. Cada etapa representa o acionamento de gradientes de campo magnético em uma dada direção.

1.1 Imagens de Endoscopia Óptica

A endoscopia óptica é um procedimento minimamente invasivo que permite ao médico observar, através de um monitor, os órgãos e tecidos do corpo humano. Com base no que precisa ser observado, existem procedimentos endoscópicos diferentes, por exemplo endoscopia digestiva, colonoscopia, broncoscopia, laparoscopia, etc. Em um processo de endoscopia tradicional, a aquisição de imagens endoscópicas é feita com o uso de um endoscópio, um tubo flexível equipado com uma câmara e uma unidade de iluminação localizado em sua ponta, cuja luz é transmitida através do uso de fibras ópticas.

Fibras ópticas são tubos estreitos de fibras de vidro com um revestimento de plástico que levam a luz de uma extremidade para a outra. A luz é injetada em um fibra sempre que o ângulo de incidência na superfície externa da fibra é maior que o ângulo crítico para reflexão interna total, cujo valor deve ser de 82° (ver [Figura 1](#)). A luz é então transportada pelo comprimento da fibra enquanto ricocheteia repetidamente dentro da mesma. Dessa forma, as fibras ópticas podem ser usadas para transportar luz de uma dada fonte até o seu destino. As propriedades das fibras ópticas as tornam úteis para uma ampla gama de aplicações, incluindo seu uso na medicina, para transmitir imagens de órgãos e artérias ([LOFTS, 2008](#)).

Figura 1 – Estrutura de uma fibra óptica incorporando reflexão interna total.



Fonte: Adaptada de [Lofts \(2008\)](#).

A imagem produzida pelas lentes de um endoscópio é focalizada em uma extremidade de um punhado de centenas de fibras ópticas. Esse punhado de fibras ópticas tem um diâmetro pequeno e flexível o suficiente para ser inserido dentro do corpo humano através de vários orifícios naturais. O eixo de seu tubo tem apenas 10 mm de diâmetro e pode ter até 2 metros de comprimento. O endoscópio é revestido em aço e plástico a fim torná-lo à prova d'água, evitar danos químicos e torná-lo fácil de manobrar através do corpo. A luz é guiada para a região de interesse por feixes de fibra óptica não coerentes (feixes onde as fibras ópticas não são alinhadas em ambas as extremidades), e as imagens são transmitidas de volta por feixes de fibra óptica coerentes (feixes onde as fibras ópticas são alinhadas em ambas as extremidades da fibra de modo que uma imagem possa ser transmitida). Para produzir imagens com qualidade aceitável, o tubo de um endoscópio

contém de 7.000 até 25.000 fibras ([BAUER; WESTFALL; DIAS, 2013](#)).

Dependendo do tipo de órgão a ser observado, o tubo do endoscópio é inserido dentro do corpo humano, através de um orifício natural ou de uma pequena incisão. Na [Figura 2](#), podemos ver ilustrações com exemplos de procedimentos clássicos de endoscopia bem como um endoscópio, algumas de suas partes constituintes e uma imagem obtida através de um endoscópio.

Figura 2 – Ilustrações de procedimentos endoscópicos, o endoscópio e imagem obtida com um endoscópio.



Fonte: Adaptada de [Lofts \(2008\)](#), com imagens retiradas da base disponibilizada pela [A.D.A.M Medical Encyclopedia](#).

Uma segunda forma de se obter imagens desse tipo é através do uso de cápsulas endoscópicas (ver [Figura 3](#)). Esse segundo tipo de procedimento é classificado como não-invasivo, simples e indolor: o paciente engole naturalmente uma cápsula com cerca de 2,5 cm, dentro da qual há uma câmera e uma fonte de luz branda LED (*Light-Emitting Diode*) capaz de registrar o percurso que a cápsula percorre.

Figura 3 – Exemplo de cápsula endoscópica e imagens obtidas com essas cápsulas.



Fonte: Adaptada de [Wu et al. \(2016\)](#).

1.1.1 Degradações Comuns em Imagens de Endoscopia Óptica

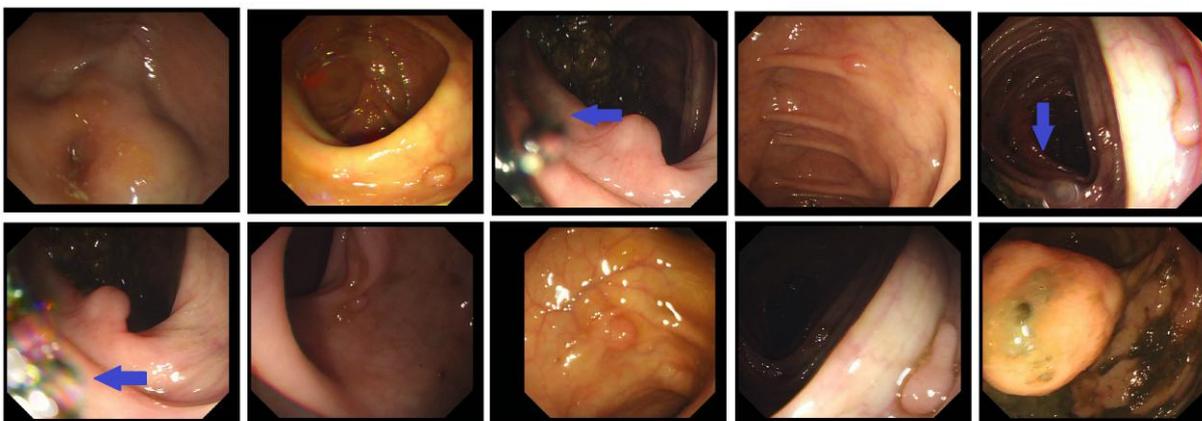
Imagens endoscópicas geralmente apresentam tecidos dos órgãos do trato gastrointestinal. Algumas imagens, quando capturadas com endoscópio, podem apresentar-se borradas devido ao movimento brusco de câmera ou devido aos movimentos involuntários relacionados ao trato (ver [Figura 4](#)). Da mesma forma, imagens capturadas por cápsulas endoscópicas são muitas vezes borradas devido principalmente a estes mesmos fatores e a restrições intrínsecas do equipamento em termos de aquisição e transmissão de imagem. Este problema, por sua vez, impõe dificuldades para um diagnóstico preciso e eficaz sobre essas imagens, como, por exemplo, a não visualização de tumores e doenças inflamatórias presentes nesse trato ([LIU; LU; MENG, 2011](#); [HEGENBART; UHL; VECSEI, 2011](#)). Em geral, imagens endoscópicas degradadas são identificadas e descartadas em processos de análise ([SUN et al., 2012](#); [GHOSH et al., 2014](#); [BERNAL; SANCHEZ; VILARINO, 2012](#)), sendo raros os trabalhos no estado da arte que dedicam-se ao processo de restauração dessas imagens ([LIU; LU; MENG, 2011](#)).

Em virtude da presença de mucosa e da aparência lisa da superfície do trato gastrointestinal, quando uma fonte de luz é aproximada, esta superfície pode apresentar **reflexos especulares** (ver [Figura 3](#) e [Figura 4](#)), e estes são outro tipo de degradação comum em imagens de endoscopia óptica ([VOGT et al., 2002](#)). Para muitos procedimentos tais como segmentação, reconhecimento de objetos, etc, estes reflexos podem se tornar uma fonte de erro, uma vez que podem produzir falsas regiões que se tornam um obstáculo em processos de análise nessas imagens ([VOGT et al., 2002](#)). Por outro lado, eles contêm informações importantes sobre a orientação da superfície quando a localização da fonte de luz e câmera são conhecidos. Tais informações podem ser utilizadas por métodos de restauração de imagens no processo de estimativa da PSF do borramento. ([HUA; LOW, 2011](#); [QUEIROZ et al., 2013](#); [HU et al., 2014](#); [LIU et al., 2016](#)).

O estado da arte apresenta alguns métodos de detecção de reflexos especulares em imagens de endoscopia óptica ([STEHLE, 2006](#); [ARNOLD et al., 2010](#); [MESLOUHI et al., 2011](#); [QUEIROZ; REN, 2014](#)). Tais métodos, em sua maioria, realizam a detecção com base em limiares sobre valores de intensidade na imagem e geram como resultado desse processo uma segmentação binária (ou grosseira) das regiões de reflexos, ou seja, a maior parte dessas técnicas produzem máscaras binárias para representar o componente que contém as specularidades presente na imagem. Nesse tipo de segmentação, muitos detalhes relativos às regiões de interesse podem ser perdidos ou outras regiões que não são de reflexos especulares podem ser desnecessariamente segmentadas.

Neste trabalho, propomos um método de restauração de imagens endoscópicas borradas por movimentação de câmera, onde a PSF da degradação (assumida invariante no espaço) é estimada a partir do agrupamento e fusão dos reflexos especulares presentes na imagem. Dessa forma, o processo de restauração é dividido em duas etapas, no qual a

Figura 4 – Imagens de endoscopia óptica apresentando *highlights* em sua superfície e regiões borradas (indicadas pelas setas em azul).



Fonte: Elaborada pela autora, com imagens extraídas da base disponibilizada por Bernal, Sánchez e Vilarino (2012).

primeira etapa consta de um processo de segmentação de reflexos especulares e a segunda etapa consta do processo de restauração em si. Quanto à segmentação dos reflexos, esta é realizada de maneira precisa, ou seja, o seu resultado deve se assemelhar a um processo de *matting* (WANG; COHEN, 2007), cujo objetivo é separar informações de primeiro plano (*foreground*) do resto da imagem (*background*), incluindo valores de transparência por pixel. Neste caso, o primeiro plano de interesse neste processo seriam os reflexos especulares presentes na imagem. Dessa forma, o método aqui proposto gera uma máscara em tons de cinza ao invés de uma máscara binária contendo tais reflexos segmentados².

1.2 Hipóteses

As hipóteses que lançamos para a presente tese são listadas abaixo:

1. Apesar dos métodos de detecção do estado da arte, que produzem seus resultados em máscaras binárias, partimos da hipótese que reflexos especulares, comumente encontrados em imagens de endoscopia óptica, podem ser segmentados de forma precisa em uma máscara em tons de cinza e sem o uso de valores limiares de intensidade nesse processo. PSFs de borramento estimadas de maneira mais precisa, ou seja, esparsas, com a trajetória do borramento bem definida e sem presença de ruídos, tendem a gerar imagens restauradas com melhor qualidade. Sendo assim, uma vez segmentados de maneira precisa, muitos dos reflexos encontrados podem ser importantes no entendimento da degradação de imagens borradas por movimento, ou seja, a PSF da degradação pode ser aproximada por muitos desses reflexos. Dessa

² Os termos “segmentação grosseira” e “segmentação precisa” serão melhor detalhados na Seção 2.2.

forma, estes podem ser utilizados como informação *a priori* no processo de estimação desta PSF;

2. O agrupamento de reflexos especulares realizado a partir de sua forma, e de características espaciais e de intensidade, pode determinar quais grupos melhor contêm informações sobre o borramento sofrido por uma imagem, uma vez que nem todos os reflexos ali presentes representam de fato esta degradação. Muitos destes reflexos podem ter uma área grande demais (nesse caso, fere-se a premissa de que a PSF estimada deve ter tamanho pequeno quando comparado ao tamanho da imagem degradada), ou localizados em áreas da superfície do trato que os dão uma aparência deformada;
3. Um único reflexo especular contido na imagem pode encontrar-se saturado ou corrompido por ruído. Sendo assim a fusão dos reflexos presentes em um dado grupo, que por sua vez se assemelham e se complementam, pode gerar uma PSF em potencial mais útil no processo de restauração da imagem do que aquela estimada através de um único reflexo;
4. A PSF estimada pela segmentação precisa dos reflexos especulares, e pelo seu agrupamento e fusão não fere os pré-requisitos de que a PSF do sistema deve ser esparsa, positiva e com um tamanho pequeno quando comparada ao tamanho da imagem sendo restaurada.

1.3 Objetivos

O objetivo geral dessa tese é propor um novo método de restauração de imagens endoscópicas degradadas por movimento do endoscópio, onde a estimação da PSF do borramento é realizada através de reflexos especulares precisamente segmentados nessas imagens.

Os objetivos específicos desta tese são:

1. Desenvolver um método de segmentação precisa de reflexos especulares com base em um processo de decomposição matricial que separa a componente esparsa (contendo estes reflexos) da componente difusa (*low-rank*) representada pela imagem sem os reflexos;
2. Explorar o uso de características de forma, características espaciais tais como tamanho e orientação; além de características de intensidade destes reflexos, a fim de identificar os que contêm informações sobre a degradação dos que são desnecessários no processo de restauração da imagem;

3. Propor um método de restauração de imagens de endoscopia óptica, onde a estimação da PSF da degradação é feita a partir da fusão de reflexos especulares previamente agrupados pelas características supracitadas;
4. Comparação da qualidade das imagens restauradas pelo método proposto em relação a alguns dos principais métodos de restauração do estado da arte, incluindo avaliações de tempos de processamento associados ao processo.

1.4 Contribuições

Abaixo citamos as contribuições deste trabalho:

1. Reflexos especulares em imagens de endoscopia óptica afetam negativamente a qualidade da percepção da imagem (VOGT et al., 2002). Uma vez que este trabalho propõe um novo método de segmentação precisa de reflexos especulares, apenas as regiões de real interesse são retiradas da imagem, permanecendo na mesma detalhes, que apesar de pequenos, são de vital importância para avaliação destas imagens, como os padrões de vasos sanguíneos pertinentes ao trato gastrointestinal. A retirada precisa de reflexos especulares pode facilitar não apenas a avaliação perceptiva por parte do médico, como também a implementação de métodos computacionais que auxiliem o diagnóstico médico sobre essas imagens;
2. No geral, para realizar análises manuais ou por computador em vídeos de endoscopia óptica faz-se necessário descartar imagens borradas, pois estas são considerados inúteis no processo de análise (SUN et al., 2012; GHOSH et al., 2014; BERNAL; SANCHEZ; VILARINO, 2012). Nesta tese apresentamos um método de restauração dessas imagens, para que as mesmas possam ser aproveitadas durante um processo de análise. Em outras palavras, a restauração dessas imagens pode auxiliar o médico em seus diagnósticos, uma vez que anomalias do trato gastro intestinal do paciente podem não ser devidamente notadas devido à degradação de borramento.

1.5 Organização do Texto

Este trabalho está organizado em seis capítulos. Neste capítulo, é realizada a contextualização do tema proposto, bem como são expostas as hipóteses relativas a pesquisa aqui desenvolvida, seus objetivos e contribuições.

No [Capítulo 2](#) apresentamos o embasamento teórico e revisão da literatura dos métodos relacionados à segmentação de reflexos especulares em imagens de endoscopia óptica e à restauração cega de imagens, onde apresentamos uma definição da formulação do borramento em imagens, com a especificação dos três tipos básicos de degradação

encontradas em imagens: borramento causado por movimentação de câmera, movimentação de objetos em cena e falta de foco. Fazemos uma apresentação da formulação do borramento invariante no espaço, bem como o principal modelo utilizado em processos de restauração de imagens considerando-se esta invariância espacial do borramento: o modelo de estimação Bayesiana. Por fim, apresentamos métodos no estado da arte que usam reflexos especulares como informações *a priori* para restauração de imagens borradas.

No [Capítulo 3](#) apresentamos nosso novo método de segmentação de reflexos especulares em imagens de endoscopia óptica, baseado na decomposição da imagem em suas componentes esparsa (*sparse*) e de baixo posto (*low-rank*).

No [Capítulo 4](#) apresentamos uma justificativa para o uso eficaz de reflexos especulares como informação *a priori* para estimar a PSF da degradação, bem como apresentamos um método para restaurar imagens de endoscopia óptica baseado no agrupamento e fusão dos reflexos previamente segmentados.

No [Capítulo 5](#) realizamos a avaliação experimental das propostas do capítulo anterior: Os métodos propostos de segmentação de reflexos especulares e de restauração de imagens endoscópicas com a PSF da degradação estimadas com base nesses reflexos.

No [Capítulo 6](#) fazemos as considerações finais sobre o trabalho desenvolvido nesta tese, bem como apresentamos trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA E TRABALHOS RELACIONADOS

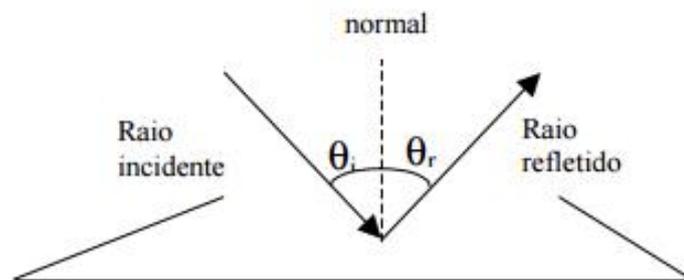
No presente trabalho, propomos um método de deconvolução cega para remoção de borramento invariante no espaço em imagens de endoscopia óptica. Neste método, a estimação da PSF da degradação é realizada utilizando-se reflexos especulares presentes na imagem.

Neste capítulo apresentamos conceitos importantes relativos à pesquisa aqui desenvolvida, e um levantamento bibliográfico realizado sobre trabalhos de detecção/segmentação de reflexos especulares em imagens de endoscopia óptica, bem como sobre trabalhos de deconvolução cega de imagens.

2.1 Reflexos Especulares e Pequenos Pontos de Luz

Reflexos especulares são resultantes de um fenômeno no qual os raios de luz incidentes em uma determinada superfície são refletidos sob um ângulo de reflexão θ_r , aproximadamente igual ao ângulo de incidência θ_i , e estes reflexos ocorrem em superfícies tais como metal, vidro, dentre outras, que no geral, são lisas e polidas (BAUER; WESTFALL; DIAS, 2013). Na Figura 5, ilustramos um exemplo de reflexão especular de um raio de luz sobre uma superfície com as propriedades acima citadas.

Figura 5 – Reflexão especular de um raio de luz sobre uma superfície lisa e polida.



Fonte: Elaborada pela autora.

Pequenos pontos de luz podem variar, por exemplo, de luzes decorativas de uma árvore de Natal, a uma lâmpada acesa em um poste de iluminação de uma cidade, dependendo da distância entre o fotógrafo e a fonte de luz. A energia luminosa provocada tanto por reflexos especulares quanto por pequenos pontos de luz presentes em uma imagem é normalmente concentrada de forma compacta e caracterizada como uma pequena região

com forte brilho que se destaca na imagem. A [Figura 6](#) ilustra alguns exemplos de imagens que contêm reflexos especulares ou pequenos pontos de luz.

Figura 6 – Exemplos de imagens que contêm reflexos especulares ou pequenos pontos de luz: pequenas fontes de luz na fotografia de uma região de uma cidade e na árvore de natal; reflexos especulares nos sapatos com superfície refletora, nos olhos da criança fotografada, na imagem resultante de um exame para detecção de catarata utilizando iluminação direta e em uma imagem de endoscopia óptica.



Fonte: Elaborada pela autora.

2.2 Detecção de Reflexos Especulares em Imagens de Endoscopia Óptica

Imagens endoscópicas mostram comumente tecidos dos órgãos do trato gastrointestinal. Devido a presença de mucosa e à aparência lisa de suas superfícies, quando uma fonte de luz é aproximada, estas apresentam reflexos especulares. A cor dominante em imagens de endoscopia óptica tem um tom rosado/avermelhado e, em geral, a fonte de luz do endoscópio é branca. Por conseguinte, devido a proximidade entre o endoscópio e a superfície dos órgãos do trato gastrointestinal, regiões intensamente brancas nas imagens de endoscopia correspondem, na maioria dos casos, a reflexos especulares ([TCHOULACK; LANGLOIS; CHERIET, 2008](#)). Nas [Figura 3](#) e [Figura 4](#), apresentamos imagens de endoscopia óptica contendo tais reflexos. As imagens exibidas nesta figura foram extraídas da base disponibilizada por [Bernal, Sánchez e Vilarino \(2012\)](#)¹.

¹ Todas as imagens de endoscopia óptica presentes nesse trabalho foram extraídas desta mesma base.

Reflexos especulares presentes em imagens de endoscopia óptica podem afetar negativamente a qualidade da imagem, e para muitos procedimentos de análise, que incluem segmentação, reconhecimento de objetos, etc, eles podem se tornar uma fonte de erros, uma vez que podem produzir falsas regiões que se tornam um obstáculo para a análise nessas imagens (VOGT et al., 2002). Por outro lado, esses mesmos reflexos contêm informações importantes sobre a orientação da superfície quando a localização da fonte de luz e câmera são conhecidos. Tais informações podem ser úteis no processo de reconstrução 3D dos órgãos do trato gastrointestinal (TCHOULACK; LANGLOIS; CHERIET, 2008) e podem também ser utilizadas por métodos de deconvolução cega para estimar a PSF do borramento apropriada para o processo de restauração dessa imagem (HUA; LOW, 2011; QUEIROZ et al., 2013; HU et al., 2014; LIU et al., 2016).

Vários métodos foram desenvolvidos para realizar a detecção de especularidades em imagens de endoscopia óptica. Nos trabalhos apresentados por Stehle (2006) e Meslouhi et al. (2011), são selecionados limiares no pico mais alto ou mais brilhante do histograma de valores de intensidade do canal Y do espaço de cor YUV . No trabalho de Cao et al. (2007), as regiões referentes à reflexões especulares são segmentadas pela análise dos valores de intensidade e saturação de *pixels*². No trabalho proposto por Arnold et al. (2010), a detecção dos reflexos especulares é realizada utilizando-se como referência os canais verde e azul da imagem colorida original. Nesse método, foram implementados módulos de limiarização baseados em valores de intensidade nos canais citados. Após esse processo, avaliações sobre magnitude do gradiente da imagem e sobre o tamanho dos reflexos previamente detectados são utilizadas para remover falsas regiões detectadas pelos processos de limiarização. Karapetyan e Sarukhanyan (2013) apresentaram uma abordagem de avaliação local realizada por janelas, onde um histograma de valores de intensidade é analisado para cada janela. Um limiar é selecionado para cada uma dessas janelas de acordo com dados do histograma da imagem. Todos os métodos acima citados, mesmo em abordagens globais ou locais, usam **limiares de valores de intensidade** no processo de detecção de reflexos especulares, o que pode gerar falsos positivos durante a detecção, uma vez que as imagens podem conter regiões com valores de intensidade altos, mas que não representa necessariamente uma região de reflexo especular, além ocasionar também na perda de reflexos especulares com valores de intensidade menores.

Chakraborty, Marcinczak e Grigat (2014) apresentaram um método para detecção de reflexos especulares e classificação de reflexos fracos em imagens de laparoscopia. Nesse trabalho, um classificador do tipo SVM (*Support Vector Machine*) é treinado para detectar contornos de reflexos especulares fracos via combinação da análise de valores de intensidade com descritores de forma. A segmentação desses reflexos foi realizada sobre estes contornos

² O termo “saturação de *pixels*” empregado aqui refere-se a valores de intensidade *pixels* causados por situações na qual a luminosidade da cena excede o alcance do sensor da câmera, deixando os destaques brilhantes para valor de intensidade de saída máximo (por exemplo, 255 para uma imagem de 8 bits).

utilizando limiarização sobre os valores de intensidade e operações morfológicas. Apesar desse trabalho tratar do problema referente à perda de reflexos menos proeminentes, o mesmo ainda usa limiares de intensidade no processo de detecção e segmentação destes mesmos reflexos.

Os métodos discutidos acima realizam uma **segmentação grosseira** das regiões de reflexos especulares, ou seja, essas técnicas produzem máscaras binárias para representar o componente que contém tais reflexos. Chamamos este tipo de segmentação de grosseira, pois muitos detalhes relativos às especularidades podem ser perdidos ou regiões vizinhas às regiões de reflexos podem ser desnecessariamente segmentadas.

Em trabalho recente, [Chwyl et al. \(2015\)](#) propuseram um método para separar as componentes especulares das componentes difusas em imagens de endoscopia óptica. Neste trabalho, essa dissociação foi realizada utilizando-se uma abordagem de estimação Bayesiana³. A cromaticidade difusa máxima que é necessária para o cálculo do coeficiente de reflexão especular, é estimada através do método dos mínimos quadrados em uma abordagem Bayesiana, com a probabilidade posterior da máxima cromaticidade difusa sendo estimada dada a cromaticidade máxima construída através de uma abordagem adaptativa de amostragem de Monte Carlo. Um diferencial deste trabalho em relação aos anteriores, é que o resultado da separação da componente especular da imagem é uma máscara em tons de cinza, que contém informações mais precisas sobre os reflexos especulares. Ao tipo de segmentação que produz esse modelo de máscara em tons de cinza em vez da máscara binária, chamaremos de **segmentação precisa**. O resultado desse tipo de segmentação deve se assemelhar a um processo de *matting* ([WANG; COHEN, 2007](#)), que separa informações de primeiro plano do resto da imagem, avaliando os valores de transparência por pixel. O método de [Chwyl et al. \(2015\)](#) considera como componente especular, todas as regiões da imagem com altos valores de intensidade, além dos reflexos especulares. Porém, para os propósitos deste trabalho, o primeiro plano de interesse no processo seria composto apenas pelos reflexos especulares presentes na imagem.

O novo método de segmentação que propomos no [Capítulo 3](#) desta tese visa o desenvolvimento de uma segmentação precisa de reflexos especulares em imagem de endoscopia óptica. Diferentemente da maioria das abordagens citadas anteriormente, não são utilizados limiares com base em valores de intensidade, realizando-se em vez disso, uma decomposição matricial que separa a componente esparsa (*sparse*) da componente difusa (*low-rank*) através do uso de um algoritmo de PCA Robusto (*Robust Principal Component Analysis*) ([GANESH et al., 2009](#)). O uso de algoritmos de RPCA para detecção/segmentação de reflexos especulares em imagens de endoscopia foi proposto pela autora desta tese ([QUEIROZ; REN, 2014](#)).

³ Cujos conceitos básicos serão apresentados na Seção [2.4.1](#).

2.3 Formulação do Problema do Borrimento de Imagens

A restauração de imagens baseia-se na tentativa de melhorar a sua qualidade através do conhecimento dos processos físicos que levaram à sua formação. A maioria das imagens nas quais estamos interessados é gerada pela interação de uma fonte de “iluminação”⁴ e a reflexão ou absorção de energia dessa fonte pelos elementos da cena cuja imagem está sendo gerada (GONZALEZ; WOODS, 2006).

O uso de Campos Aleatórios de Markov (MRFs - *Markov Random Fields*) tornaram-se úteis em várias áreas de processamento de imagem uma vez que eles dão origem a bons modelos estocásticos de imagem (GEMAN; GEMAN, 1984). Modelos de imagens usando MRFs são versáteis o suficiente para serem aplicados nas áreas de síntese de imagem e textura, compressão de imagens, restauração de imagens, dentre outros. Em um trabalho clássico, Geman e Geman (1984) mostraram que se um MRF é degradado por borrimento invariante no espaço, distorcido e corrompido por ruído Gaussiano aditivo branco, a distribuição do MRF original (não degradado), dada sua versão degradada, continua sendo markoviana. Partindo dessa dedução, os autores deste trabalho implementaram um algoritmo pioneiro de restauração de imagens degradadas por borrimento e ruído Gaussiano. Bustos e Frery (1992) generalizaram ainda mais o modelo de Geman e Geman (1984), quando propuseram uma extensão do mesmo para casos em que o ruído da degradação não apresenta necessariamente uma distribuição gaussiana. O modelo proposto por Bustos e Frery (1992) pode ser visto na Equação 2.1 abaixo:

$$B = \phi(k(I)) + \varepsilon \quad (2.1)$$

neste modelo, se B é um MRF sob ação de borrimento, k corresponde a uma PSF invariante no espaço, a distorção ϕ implica em uma transformação não linear sobre $k(I)$ e ε equivale a qualquer campo markoviano com respeito ao sistema de vizinhança introduzido pelo borrimento k ; então, a distribuição *a posteriori* $P(I = i | B = b)$ é também um MRF.

Em sistemas de captura de imagens 2D, assumindo a suposição de ruído Gaussiano independente e identicamente distribuído (i.i.d.) e degradação invariante no espaço (também conhecida por **degradação uniforme**), o problema de degradação exposto na Equação 2.1 pode ser definido de acordo com a Equação 2.2:

$$B(\mathbf{x}) = f((I * k)(\mathbf{x})) + \eta(\mathbf{x}) \quad (2.2)$$

⁴ O termo iluminação está entre aspas para enfatizar o fato de que elas são consideravelmente mais genéricas que a situação habitual na qual uma fonte de luz visível ilumina uma cena tridimensional comum. Esta iluminação pode se originar de uma fonte de energia eletromagnética como um sistema de raios X ou infravermelho, por exemplo, ou pode se originar de fontes menos tradicionais, como ultrassom, acústica e eletrônica.

no qual $*$ denota uma operação de convolução, B se refere a imagem borrada ao qual temos acesso, k é a PSF de degradação, $f(\cdot)$ denota a função não linear de resposta de câmera (*Camera Response Function* - CRF) que mapeia a irradiância da cena para valores de intensidade na imagem e $\eta(\mathbf{x})$ refere-se ao ruído Gaussiano de média zero em cada pixel $\mathbf{x} = (x, y)$ da imagem (WANG; TAO, 2014).

Para simplificar o problema, a maioria dos trabalhos em restauração de imagens negligencia o efeito do CRF ou explora tal efeito como um passo de pré-processamento (LEVIN et al., 2009; WANG; TAO, 2014). Sendo assim, podemos remover o efeito do CRF para obter uma formulação ainda mais simplificada da Equação 2.2. Essa formulação mais simplificada do problema é apresentada pela Equação 1.1 e será utilizada no decorrer desta tese.

Considerar uma PSF k invariante no espaço, indica que sua resposta em qualquer ponto \mathbf{x} da imagem depende somente do valor de entrada nesse ponto, e não de sua posição. No caso da degradação causada por movimentação de câmera, essa PSF faz com que um pixel da imagem represente informação de luminosidade provenientes de vários pontos da cena, provocando assim o efeito de borramento da imagem. Como já foi previamente mencionado, ao processo de remoção desse tipo de degradação dá-se o nome de desborramento (*image deblurring*), e este é um problema inverso clássico que busca estimar imagens nítidas I a partir de imagens B degradadas por borramentos e ruído.

Vale salientar que o processo de formação descrito na Equação 1.1 não pode ser considerado como o único modelo para descrever a formação de imagens. A maioria das situações relativas à captura de imagens requerem um modelo mais complexo, como modelos de borramento variantes no espaço, contudo, o entendimento da degradação pode ser facilitado por meio de um estudo de uma abordagem invariante no espaço. Sendo assim, no decorrer deste trabalho trataremos de discutir métodos de restauração baseados na invariância espacial da degradação.

Como já mencionamos no Capítulo 1, muitos fatores podem causar intrinsecamente ou extrinsecamente o borramento de imagens. Nesse trabalho, apontaremos a classificação dessa degradação em três tipos básicos previamente definida por Wang e Tao (2014): 1) borramento causado por movimentação de câmera, 2) borramento causado por falta de foco e 3) borramento causado por movimentação de objetos na cena. Cada um desses tipos de borramento degradam a imagem de maneiras diferentes. Em diversos métodos de deconvolução de imagens, uma melhor estimativa da imagem nítida I e da PSF k requer um conhecimento adequado sobre processo de borramento da imagem, por isso este trabalho possui um espaço dedicado à explanação de cada um desses três tipos de degradação.

2.3.1 Degradação Causada por Movimentação de Câmera

Com algumas exceções, como em alguns tipos de fotografia artística, a trepidação da câmera é indesejável, uma vez que frequentemente destrói detalhes e borra a imagem. Esse tipo de degradação é induzida pelo movimento da câmera durante o período de exposição. Isto é particularmente comum em fotografias capturadas à mão, principalmente, em situações de pouca luz, por exemplo, no interior de edifícios ou à noite. Esta degradação pode ser muito complexa, uma vez que as mãos podem se mover em uma direção irregular durante o momento de captura da imagem (RAJAGOPALAN; CHELLAPPA, 2014). Uma situação ideal de movimentação de câmera produziria uma degradação invariante no espaço formulado pela Equação 1.1 e assim, se o movimento da mesma fosse rápido em relação ao período de exposição, a distribuição da PSF k poderia ser facilmente modelada por uma função que definisse um movimento linear. Na Figura 7 mostramos um exemplo de uma imagem nítida que foi borrada de maneira uniforme, e cuja PSF k representa um movimento linear com direção de 180° .

Figura 7 – Exemplo de borramento por movimentação de câmera ideal.



Fonte: Elaborada pela autora.

Contudo, o movimento da câmera durante a aquisição da fotografia não se encaixa no modelo ideal, sendo o mesmo definido de forma mais complexa. Esse movimento complexo pode ser dado por uma sequência de movimentos de translação e rotação que podem ocorrer de forma independente ou simultânea durante a captura da imagem. Sendo assim, no momento da captura, as informações espaciais da câmera podem ser dadas por posição e orientação, sendo que, na maioria dos casos de movimentação da câmera, as mudanças relativas à orientação durante a exposição têm um efeito significativamente maior do que as alterações na posição (WHYTE; SIVIC; ZISSERMAN, 2011; WHYTE

et al., 2012). Podemos representar a orientação da câmera de acordo com a definição de $\theta_{xyz} = (\theta_x, \theta_y, \theta_z)$, que contém os ângulos que recebem o nome de empinamento (*pitch*), cabeceio (*yaw*) e balanceio (*roll* ou *in-plane rotation*), respectivamente. A Figura 8 ilustra os eixos desse movimento complexo da câmera.

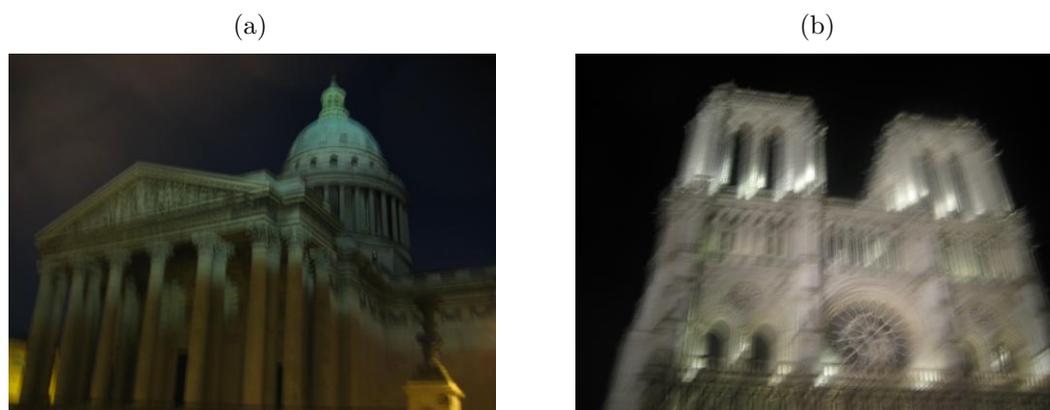
Figura 8 – Movimentação complexa de uma câmera em diferentes eixos geram degradações compostas por sequências arbitrárias de orientação.



Fonte: Adaptado de Whyte et al. (2012).

Como podemos observar na Figura 8, devido a essa sequência de movimentos de rotação da câmera no momento da captura, a degradação assume trajetórias com formas aleatórias e, portanto, não é uniforme na imagem, ou seja, a depender de regiões específicas na imagem, ela pode apresentar características ligeiramente diferentes (ver Figura 9). Sendo assim, a formulação de degradação apresentada pela Equação 1.1, que por sua vez, modela o borrimento causado por movimentação de câmera como um processo de convolução espacial invariante no espaço, é insuficiente para descrever os efeitos causados pelo borrimento variante no espaço que ocorre em situações de movimentação de câmera reais.

Figura 9 – Degradação causada por movimentação de câmera: a depender de regiões específicas na imagem, o borrimento pode apresentar características ligeiramente diferentes.



Fonte: Adaptado de Wang e Tao (2014).

Vale salientar que, mesmo diante desse fato, devido à sua simplicidade, muitos trabalhos presentes no estado da arte utilizam, no processo de restauração de imagens, o modelo de degradação invariante no espaço descrito pela [Equação 1.1](#) para modelar o borramento causado por movimento de câmera ([FERGUS et al., 2006](#); [SHAN; JIA; AGARWALA, 2008](#); [LEVIN et al., 2009](#); [CHO; LEE, 2009](#); [XU; JIA, 2010](#); [QUEIROZ et al., 2013](#); [SHEARER; GILBERT; III, 2013](#); [HU et al., 2014](#); [PAN et al., 2016](#)). Dentre as abordagens que tratam de uma modelagem variante no espaço do borramento causado por movimentação de câmera, destaca-se a modelagem baseada em homografia ([WHYTE et al., 2010](#); [JOSHI et al., 2010](#); [CHO et al., 2012](#); [XU; ZHENG; JIA, 2013](#)), que é geralmente proposta para simular o efeito causado por tal borramento.

2.3.2 Degradação Causada por Falta de Foco

Devido a fatores como uma focagem mal realizada pelo sistema de imagem ou devido a diferentes profundidades encontradas na cena fotografada, alguns campos da imagem podem sofrer o efeito da degradação causada por falta de foco. Esse tipo de degradação é bastante corriqueiro em nossas fotos cotidianas. Partes do cenário, que encontram-se fora do campo de profundidade (DOF - *Depth Of Field*), que é a região da imagem que encobre todos os objetos da cena com nitidez aceitável, aparecem borradas na imagem capturada. A [Figura 10](#) ilustra um exemplo de uma imagem borrada por falta de foco.

Figura 10 – borramento causado por falta de foco.



Fonte: Imagem retirada da base disponibilizada por [Shi, Xu e Jia \(2015a\)](#)

Na prática, focar em um objeto de destino da cena não é difícil para as câmeras modernas (mesmo as mais simples) já que a maioria delas é equipada com uma função de auto-foco. Porém, devido a um DOF limitado, nem sempre é possível fotografar uma imagem completamente nítida. Muitos trabalhos de restauração propõem algoritmos específicos que modelam esse tipo de degradação ([LE et al., 2009](#); [SHEN; HWANG; PEI,](#)

2012), e muitos destes levam em consideração informações de profundidade na imagem para detectar previamente as regiões que encontram-se desfocadas (TAI; BROWN, 2009). Sendo assim, fica evidente deduzirmos que, na maioria dos casos, uma vez que esse tipo de degradação acontece apenas em partes específicas da imagem ficando o resto da imagem, em geral, nítida; a escolha de um modelo de degradação invariante no espaço não é a melhor alternativa para a modelagem do mesmo.

2.3.3 Degradação Causada por Movimentação de Objetos em Cena

Esse tipo de degradação é causada pelo movimento relativo entre um objeto na cena e a câmera durante o tempo de exposição. Geralmente esta degradação ocorre quando tentamos capturar um objeto em movimento rápido ou quando é necessário um longo tempo de exposição, estas cenas são então denominadas **cenar dinâmicas**, enquanto que as cenas contendo apenas borramento por movimentação de câmera e/ou falta de foco são chamadas de **cenar estáticas**. A Figura 11 ilustra um exemplo de imagem que contém esse tipo de degradação.

Figura 11 – Cena dinâmica com degradação causada por movimentação de objetos em cena.



Fonte: Imagem retirada da base disponibilizada por Shi, Xu e Jia (2015a).

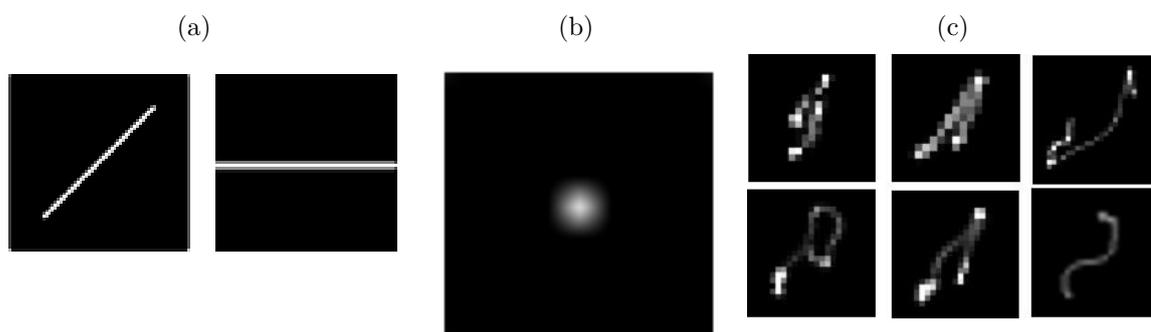
Tal qual em imagens degradadas por falta de foco, podemos observar que esse tipo de degradação não é uniforme na imagem. Nesses casos, diferentemente da degradação causada por movimentação de câmera, partes da imagem mantêm-se nítidas enquanto outras são degradadas pelo borramento. Dessa forma, o modelo apresentado pela Equação 1.1 também mostra-se insuficiente para modelar este tipo de borramento, uma vez que a deconvolução com uma única PSF poderia restaurar parte da imagem (aquelas já degradadas) enquanto degradaria outras partes da mesma (aquelas que se encontram nítidas e não necessitam de restauração). Muitos trabalhos de deconvolução propõem algoritmos específicos que

modelam esse tipo de degradação e as abordagens mais usuais tratam de realizar uma prévia separação dos objetos borrados do restante da imagem antes de efetuar a restauração da mesma (SHI; XU; JIA, 2014; SHI; XU; JIA, 2015b). Sendo assim, a maioria dos métodos de restauração de cenas dinâmicas são denominados de **métodos de restauração baseados em regiões** (*region-based methods*) (LEVIN, 2006; TAI et al., 2010; HIRSCH et al., 2011; HARMELING; MICHAEL; SCHÖLKOPF, 2010).

2.3.4 PSFs de Degradação em Imagens

Na Figura 12 ilustramos diversos tipos de PSFs que podem ser atribuídas a diversos tipos de borramento, dentre as quais podemos destacar as PSFs paramétricas (GAST; SELLENT; ROTH, 2016), que definem borrarmentos lineares⁵, as PSFs com uma aparência aproximadamente gaussiana que definem borrarmentos por falta de foco e as PSF não paramétricas que definem movimentos de câmera aleatórios.

Figura 12 – Exemplos comuns de PSF: (a) Degradação por movimento linear: PSFs paramétricas; (b) Degradação por falta de foco: PSFs aproximadas por distribuições gaussianas; (c) Degradação por movimentos aleatórios: PSFs não paramétricas.



Fonte: Elaborada pela autora.

2.4 Restauração de Imagens com Borrimento Invariante no Espaço

Dada a formulação apresentada pela Equação 1.1, o objetivo geral do processo de deconvolução de imagens consiste em, a partir da observação B , estimar uma imagem nítida I enquanto remove, simultaneamente, os efeitos do ruído η . Quando desconhecemos apenas a imagem nítida I nesse processo, este recebe o nome de deconvolução não-cega. Porém, quando tanto I quanto k são desconhecidos, o processo é denominado deconvolução cega. Na prática, os métodos de deconvolução cega são mais úteis para realizar a remoção

⁵ PSFs paramétricas são aquelas que podem ser modeladas através de funções ou distribuições paramétricas.

do borramento de imagens, uma vez que na maior parte dos casos, a PSF do processo de degradação não é conhecida.

Deconvolução cega de imagens consiste em um problema inverso severamente mal posto, sendo assim, de acordo ainda com a [Equação 1.1](#), existe uma infinidade de pares (I, k) que conseguem explicar a imagem borrada B . Em seu trabalho, [Levin et al. \(2009\)](#) apresentaram o exemplo de uma solução indesejável, porém que satisfaz perfeitamente a [Equação 1.1](#), é a **explicação do não-borramento** ou **efeito delta** (*no-blur explanation* ou *delta effect*), onde k é definida por uma função generalizada *delta de Dirac* δ e logo, temos $I \approx B$. A [Figura 13](#) ilustra esta e algumas outras possíveis soluções deste problema. A natureza mal posta desse problema implica na ideia de que o mesmo precisa ser regularizado, ou seja, informações *a priori* relativas tanto a I quanto a k podem ser introduzidas ao problema para ajudar em sua solução. Em Estatística, inferência Bayesiana atualiza o *status* da probabilidade de uma variável desconhecida através da adição de informações *a priori*. Na Subseção [2.4.1](#), apresentaremos um modelo probabilístico para esse problema, bem como um estimador presente no contexto Bayesiano denominado Máximo *a Posteriori* (MAP), muito utilizado para resolver problemas de deconvolução cega.

2.4.1 Formulação Probabilística e o *Framework* Bayesiano

Modelos generativos são um meio de especificar funções densidade de probabilidade, no qual dadas duas variáveis aleatórias X e Y ; sendo que X descreve uma evidência, enquanto Y descreve uma variável desconhecida. Buscamos definir um modelo desses dados a partir da probabilidade conjunta $p(X, Y)$, que por sua vez é inferida por meio do **Teorema de Bayes**, onde se é possível calcular $p(Y|X)$ e dessa forma, selecionar o valor de Y mais provável:

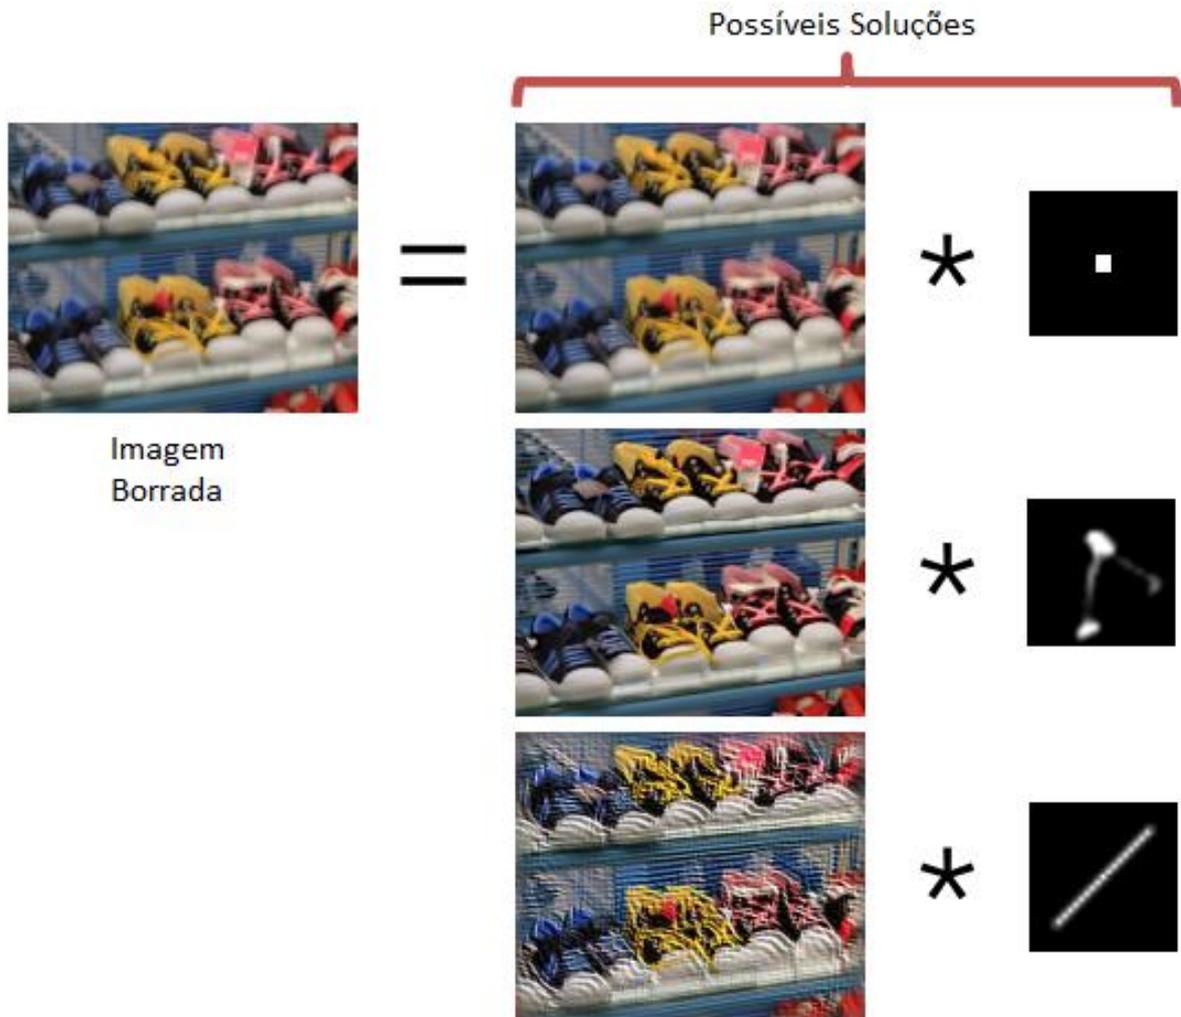
$$p(Y|X) = \frac{p(Y)p(X|Y)}{p(X)} \quad (2.3)$$

Dado o modelo geral de degradação apresentado pela [Equação 1.1](#), um ponto de partida natural para algoritmos de deconvolução cega seria descrevermos um modelo probabilístico generativo que contemple a imagem observada B e a informação desconhecida, que no problema de deconvolução cega, é representada pelo par (I, k) :

$$p(I, k|B) = \frac{p(B|I, k)p(I)p(k)}{p(B)} \propto p(B|I, k)p(I)p(k) \quad (2.4)$$

Considerando que I e k são independentes, se o tipo de ruído que afeta a imagem observada for conhecido, podemos descrever o termo de verossimilhança $p(B|I, k)$, que é a densidade de probabilidade de B condicionado a I e k . Ademais, como é possível observar na [Equação 2.4](#), havendo conhecimento prévio sobre as variáveis desconhecidas (I, k) a serem inferidas, usando o teorema de Bayes, pode-se formular a distribuição *a posteriori*

Figura 13 – Deconvolução cega de imagens vista como um problema inverso severamente mal posto: algumas possíveis soluções do problema, incluindo a explicação do não-borramento (primeira possível solução de cima para baixo), onde k é definida por um kernel cuja aparência se assemelha a uma função generalizada *Delta de Dirac* δ e logo, temos $I = B$.



Fonte: Adaptado de [Cho e Lee \(2009\)](#).

$p(I, k|B)$. Essa distribuição refere-se à probabilidade que surge a partir do ruído aleatório na imagem observada, e também do conhecimento prévio sobre as variáveis desconhecidas. O denominador da distribuição *a posteriori* (chamado de probabilidade marginal) não depende de I ou k e, portanto, não desempenha nenhum papel em futuros processos de otimização para se estimar (I, k) .

2.4.2 Estimador Máximo *a Posteriori* - $\text{MAP}_{I,k}$

Uma vez que desejamos encontrar estimativas \hat{I} para a imagem nítida I e \hat{k} para a PSF do sistema k que melhor correspondam à imagem observada B , uma escolha seria estimá-los pela maximização da distribuição *a posteriori* $p(I, k|B)$. O estimador

mais comumente usado em um quadro de inferência Bayesiana é o Máximo *a posteriori* (MAP). Esta estratégia tenta encontrar a solução ótima (\hat{I}, \hat{k}) que maximiza a distribuição *a posteriori* $p(I, k|B)$. No caso da deconvolução cega o estimador MAP poderia ser representado pela [Equação 2.5](#):

$$(\hat{I}, \hat{k}) = \arg \max_{I, k} p(I, k|B) = \arg \max_{I, k} p(B|I, k)p(I)p(k) = \arg \min_{I, k} -\log p(B|I, k)p(I)p(k) \quad (2.5)$$

Se tomarmos uma solução estimada \hat{I} para a distribuição I , convoluirmos com a PSF estimada \hat{k} e subtrairmos o resultado da saída B , o resíduo (ou seja, $\hat{\eta} = B - \hat{I} * k$) deve ter uma distribuição de ruído com as mesmas propriedades estatísticas do modelo de ruído η assumido na degradação. Qualquer estrutura espacial no resíduo que não seja consistente com o modelo de ruído η indica que a solução não é consistente com a [Equação 1.1](#). O termo de verossimilhança $p(B|I, k)$ é definido de acordo com o modelo de ruído assumido no processo de degradação. Em geral, para o modelo de degradação apresentado pela [Equação 1.1](#), assumimos um ruído Gaussiano i.i.d ⁶:

$$p(B|I, k) = \prod_i \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{[B_i - (I * k)_i]^2}{2\sigma^2}} \quad (2.6)$$

em que i indica a localização do ruído na imagem. O ruído Gaussiano assumido tem média 0 e variância σ^2 . O termo $p(B|I, k)$ é conhecido também como termo de ajuste de dados (*data fitting*), e logo $-\log p(B|I, k) = -\lambda \|I * k - B\|^2$, com λ equivalendo a um valor constante. Na [Figura 14](#) apresentamos um diagrama que ilustra esse tipo de estimação.

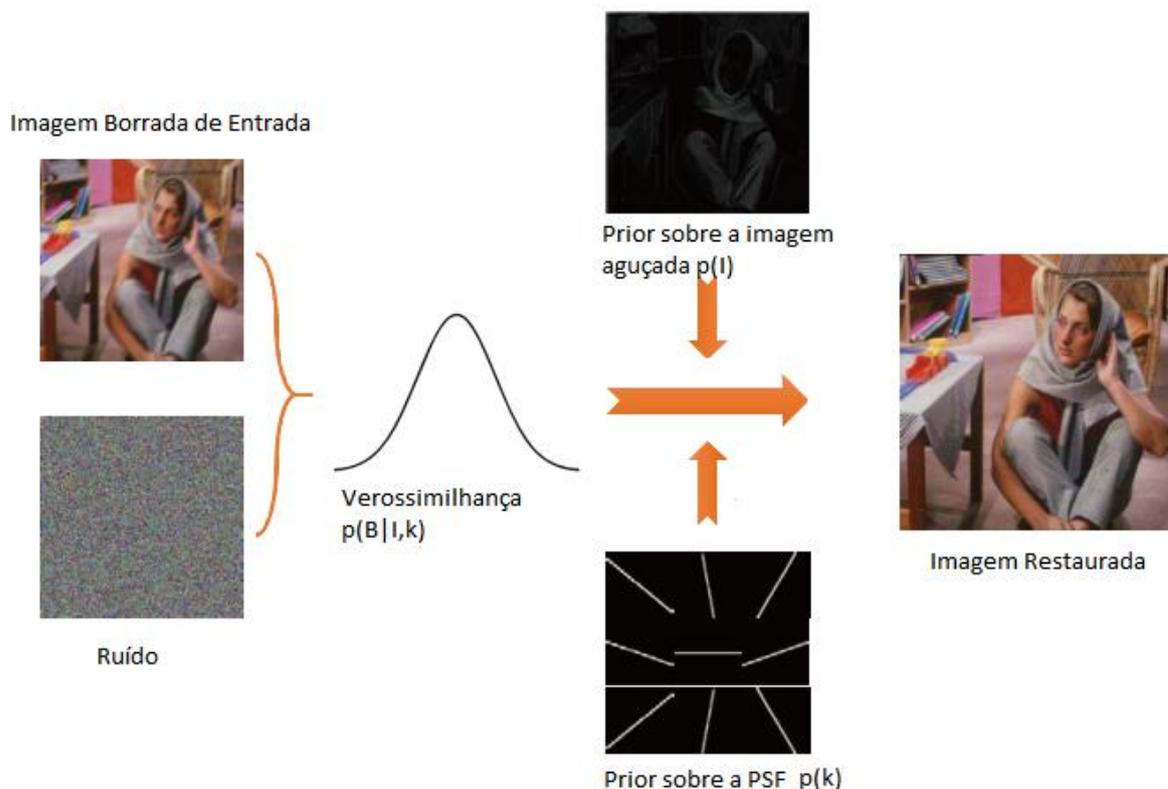
Inúmeros trabalhos presentes no estado da arte utilizam o estimador MAP para estimar o par (\hat{I}, \hat{k}) em algoritmos de deconvolução cega de imagens ([BENICHOUX; VINCENT; GRIBONVAL, 2013](#); [KRISHNAN; TAY; FERGUS, 2011](#); [XU; ZHENG; JIA, 2013](#); [CHO; LEE, 2009](#); [SHAN; JIA; AGARWALA, 2008](#); [XU; JIA, 2010](#)). Dentre outros fatores, umas das características que diferencia a maioria destes algoritmos são os termos de regularização utilizados como informação *a priori* para encontrar tanto \hat{I} quanto \hat{k} . Nas subseções abaixo veremos alguns termos *a priori* bastante comuns utilizados nesse método de estimação.

2.4.2.1 Regularização para a imagem nítida I

Em geral, o termo *a priori* $p(I)$ da [Equação 2.5](#) favorece imagens naturais, comumente com base na observação de que a magnitude do seu gradiente obedece a uma

⁶ Alguns métodos da literatura também assumem um ruído de *Poisson* ([KENIG; KAM; FEUER, 2010](#); [MA et al., 2013](#)) ou ruído impulsivo ([CHAN; DONG; HINTERMULLER, 2010](#); [CAI; CHAN; NIKOLOVA, 2009](#)) no modelo de degradação.

Figura 14 – Contexto Bayesiano de estimação: Algum conhecimento prévio sobre (I, k) deve ser incluído no problema com o intuito de melhorar a restauração condicionando e estabilizando a solução.



Fonte: Adaptado de Wang e Tao (2014)

distribuição de cauda pesada (ROTH; BLACK, 2005; WEISS; FREEMAN, 2007). Uma medida utilizada com frequência é definida pela Equação 2.7:

$$-\log p(I) = \sum_i (|\nabla_{x,i}(I)|^\alpha + |\nabla_{y,i}(I)|^\alpha) + C \quad (2.7)$$

em que $\nabla_{x,i}(I)$ e $\nabla_{y,i}(I)$ denota as derivadas horizontais e verticais no pixel i , enquanto C equivale a um valor constante. Os valores de expoente α geralmente encontram-se no intervalo de $[0.5; 0.8]$ (SIMONCELLI, 1999). Outras opções incluem um termo de regularização com distribuição Laplaciana, com $\alpha = 1$, e distribuição Gaussiana, com $\alpha = 2$ (ver Figura 15a). Devido ao ajuste imperfeito dos termos de regularização acima citados à real distribuição da magnitude do gradiente de imagens nítidas naturais, estes métodos tendem a remover texturas de média frequência, apesar de estruturas como as bordas serem preservadas no processo de restauração (WANG; TAO, 2014). Para melhorar o ajuste para a distribuição de cauda pesada do gradiente, Fergus et al. (2006) propuseram o uso de um modelo de *mistura de Gaussianas* (*Gaussian Mixture Model* - GMM) com o

número de misturas finito (ver [Figura 15b](#)), de acordo com a [Equação 2.8](#):

$$p(I) = \prod_i \sum_{j=1}^J w_j \mathcal{N}(\partial I_i | 0, \varsigma_j) \quad (2.8)$$

em que i indexa a localização de um dado pixel, J é o numero total de gaussianas, w_j e ς_j referem-se a um fator de peso e desvio padrão da j -ésima distribuição gaussiana.

Já [Shan, Jia e Agarwala \(2008\)](#) propuseram em seu trabalho, um termo de regularização definido por partes e exibidos pela equação [Equação 2.9](#):

$$p(I) = \prod_i e^{\phi(\partial I_i)} \quad (2.9)$$

em que i indexa a localização de um dado pixel e $\phi(\partial I_i) = \begin{cases} -q|\partial I_i|, & \text{se } \partial I_i \leq l_i \\ -(a(\partial I_i)^2 + b), & \text{se } \partial I_i > l_i \end{cases}$, com o índice l_i indicando a posição em que as duas funções são concatenadas e os valores de $q = 2.7$, $a = 6.1 \times 10^{-4}$ e $b = 5.0$ (ver [Figura 15c](#)).

Em resumo, termos *a priori* dessa natureza são exaustivamente utilizados em processos de deconvolução de imagens ([FERGUS et al., 2006](#); [KRISHNAN; FERGUS, 2009](#); [KRISHNAN; TAY; FERGUS, 2011](#); [LEVIN et al., 2007](#); [SHAN; JIA; AGARWALA, 2008](#)).

2.4.2.2 Regularização para a PSF k

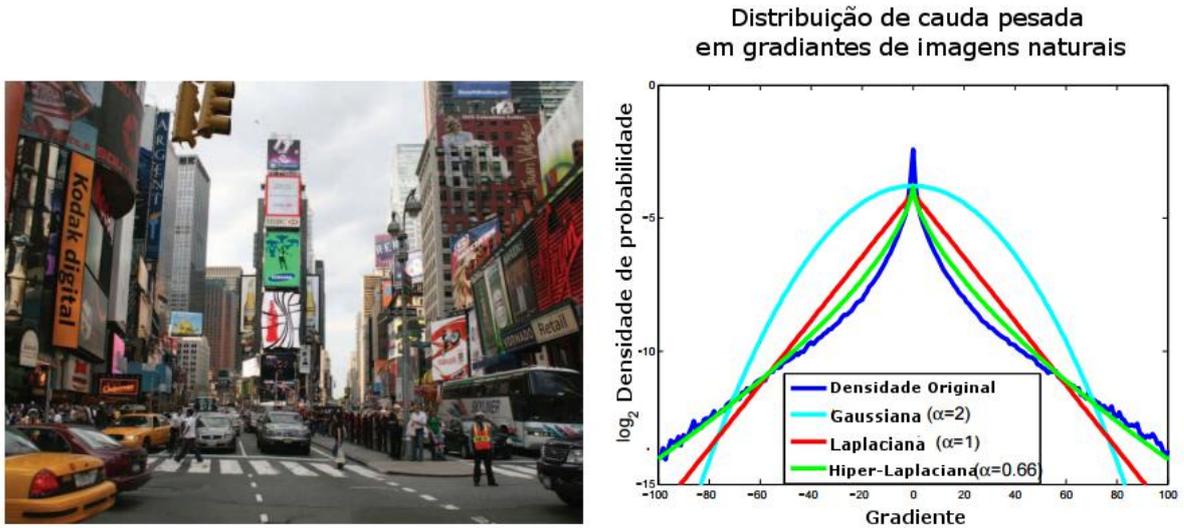
A definição de $p(k)$, em geral, está relacionada com o tipo de borramento ao qual a imagem degradada foi submetida. Quando o borramento é causado por falta de foco, é comum aproximar-se $p(k)$ por distribuições Gaussianas ([TAI; BROWN, 2009](#); [GUREYEV et al., 2004](#)) (ver [Figura 12b](#)).

Algoritmos que obtiveram sucesso nas estimação das PSFs relativas à movimentação da câmera, geralmente compartilham duas importantes propriedades para a definição de $p(k)$: Em primeiro lugar, considera-se que os elementos da PSF são não-negativos. O segundo fato a se observar sobre esse tipo de PSF é que ela deve ser esparsa ([LEVIN et al., 2009](#)). A [Figura 12c](#) mostra algumas PSFs geradas por processos de movimentação de câmera, que por sua vez, claramente exibem as duas propriedades acima citadas. Levando-se em consideração essa não-negatividade e esparsidade da PSF do borramento causado por movimentação de câmera, [Fergus et al. \(2006\)](#) encorajaram o uso da mistura de distribuições exponenciais para definir $p(k)$:

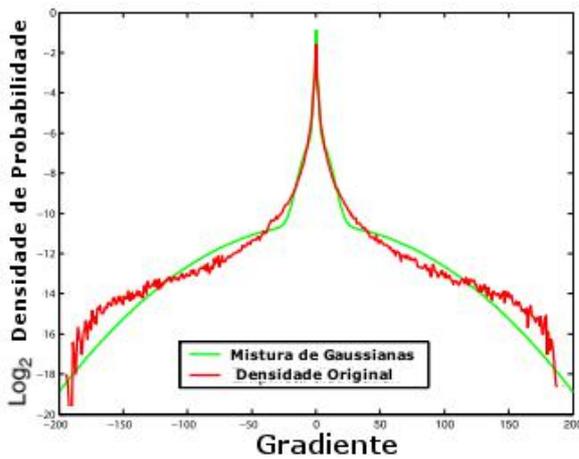
$$p(k) = \prod_j \sum_{d=1}^D \pi_d \mathcal{E}(k_j | \lambda_d) \quad (2.10)$$

Figura 15 – Termos *a priori* para a imagem nítida I : (a) Relação entre a distribuição da magnitude do gradiente de uma imagem natural com distribuições com valores de α iguais a 0.66, 1 e 2; (b) Relação entre a distribuição da magnitude do gradiente de uma imagem natural com distribuição gerada por mistura de Gaussianas; (c) Relação entre a distribuição da magnitude do gradiente de uma imagem natural com uma função definida por partes.

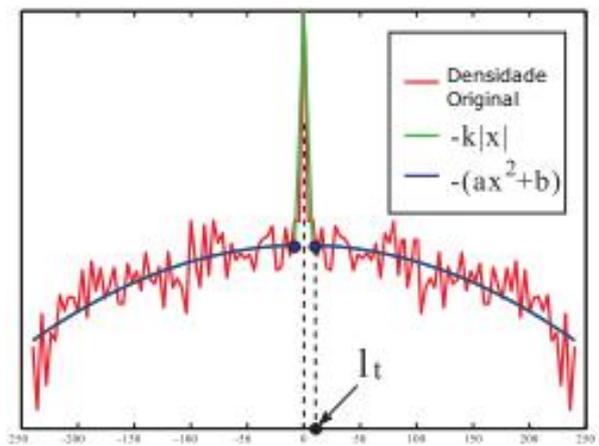
(a)



(b)



(c)



Fonte: Adaptado de Krishnan e Fergus (2009), Fergus et al. (2006) e Shan, Jia e Agarwala (2008)

neste caso, j indexa sobre os elementos da PSF do borramento, π_d se refere ao peso da mistura da d -ésima distribuição exponencial \mathcal{E} , com uma taxa λ_d . Tanto π_d quanto λ_d foram obtidos a partir de uma base de dados com PSFs reais. Em outro trabalho do estado da arte, Shan, Jia e Agarwala (2008) utilizaram uma única distribuição exponencial para

definir $p(k)$:

$$p(k) = \prod_j \lambda e^{(-\tau k_j)} \quad (2.11)$$

em que j também indexa sobre os elementos da PSF do borramento e τ define um valor constante. Outros trabalhos também assumem uma distribuição uniforme para definir $p(k)$ (LEVIN et al., 2009; LEVIN et al., 2011).

2.4.2.3 Distribuição Marginal e MAP_k

Levin et al. (2009) mostraram que estimar I e k alternadamente usando o estimador MAP _{I,k} e termos de regularização para I favorecendo imagens naturais⁷, pode não ser a melhor escolha. Embora sejam intuitivos, existe muitos problemas com os modelos MAP _{I,k} , dos quais podemos destacar os inconvenientes relacionados a mínimos globais ineficazes, em que por exemplo, uma regularização pobre pode levar à soluções como a imagem restaurada semelhante à imagem borrada, ou convergências para muitos mínimos locais que não favorecem a uma boa solução.

Para simplificar a exposição do problema, Levin et al. (2009) propuseram uma distribuição uniforme para $p(k)$ e usou as distribuições de $p(B|I, k)$ e $p(I)$ de acordo com a Equação 2.6 e Equação 2.7, respectivamente. Sendo assim, Levin et al. (2009) mostraram que a solução do problema exposto pela Equação 2.12 geralmente favorece um resultado com uma imagem ainda borrada ao invés de uma imagem nítida, ou seja, favorece a solução onde \hat{k} indica uma função generalizada delta de Dirac δ e logo, temos $\hat{I} \approx B$. Como já mencionamos previamente, essa observação é também conhecida como explicação do não-borramento ou efeito delta.

$$\begin{aligned} (\hat{I}, \hat{k}) &= \arg \max_{I, k} p(I, k|B) \\ &= \arg \min_{I, k} -\log p(I, k|B) \\ &= \arg \min_{I, k} -\log[p(B|I, k)p(I)p(k)] \\ &= \arg \min_{I, k} -\log p(B|I, k) - \log p(I) - \log p(k) \\ &= \arg \min_{I, k} \|I * k - B\|^2 + \sum_i |\nabla_{x,i}(I)|^\alpha + |\nabla_{y,i}(I)|^\alpha + C \end{aligned} \quad (2.12)$$

Porém, ainda de acordo com Levin et al. (2009), a forte assimetria entre a dimensionalidade de I e k fornece uma propriedade favorável para lidar com o problema da

⁷ Segundo Hyvriinen, Hurri e Hoyer (2009), a definição de imagens naturais não é trivial. Porém o autor as define como um conjunto de imagens que possuem estruturas estatísticas ao qual nosso sistema visual está adaptado cotidianamente.

deconvolução cega. Isto significa que, enquanto a dimensionalidade de I aumenta com o tamanho da imagem, o tamanho de k permanece fixo e é pequeno em relação à imagem. Sendo assim, de acordo com Levin et al. (2011), matematicamente, o estimador MAP_k pode ser definido pela Equação 2.13:

$$\hat{k} = \arg \max_k p(k|B) = \int p(I, k|B) dI \quad (2.13)$$

Uma vez que a PSF \hat{k} é encontrada, \hat{I} pode então ser estimada posteriormente através de um método de deconvolução não cega. Em trabalho subsequente, Levin et al. (2011) apontaram que o estimador MAP_k é geralmente complexo e difícil de ser computado pois a o cálculo de distribuição marginal definido na Equação 2.13 envolve todas as possíveis explicações de I , que por sua vez, é computacionalmente intratável. Muitas das técnicas que propõem meios de aproximar a solução desse problema são classificadas dentro do contexto do **Modelo Bayesiano Variacional** (*Variational Bayes Model* - VBM) (FERGUS et al., 2006; LEVIN et al., 2009; LEVIN et al., 2011; AMIZIC; MOLINA; KATSAGGELOS, 2012; WIPF; ZHANG, 2013).

2.5 Restauração de Imagens Utilizando *Highlights*

Muitos trabalhos também fazem uso da própria estrutura da imagem a ser restaurada como informação *a priori* para realizar a estimativa de k e em seguida usá-la em um método de deconvolução não cega a fim de estimar I . Nos trabalho proposto por Pan et al. (2016), os autores fazem uso de canais escuros (*dark channels*) na estimação de k ; enquanto que em outros trabalhos, mapas de arestas (CHO; LEE, 2009; XU; JIA, 2010) são utilizados. Outros métodos fazem uso de *highlights* (*light streaks* ou *light spots*) contidos na imagem para também auxiliar na estimativa de k (HUA; LOW, 2011; HU et al., 2014; QUEIROZ et al., 2013; LIU et al., 2016). Aqui, o termo “*highlights*” foi empregado no lugar do termo “reflexos especulares”, por ser mais amplo, incluindo também a representação de pequenos pontos de luz, além dos próprios reflexos encontrados nas imagens (ver Seção 2.1). Nesta seção, tratamos de apresentar alguns desses trabalhos que usam *highlights* na estimativa da PSF do sistema.

Em seu trabalho, Hua e Low (2011) propuseram um método invariante no espaço de remoção de degradação no qual a PSF da degradação é estimada a partir de *highlights* chamados pelos autores de *light streaks*. A escolha do *highlight* usado na estimação da PSF é feita manualmente pelo usuário. Sendo assim, seja P o fragmento da imagem selecionado pelo usuário⁸, a intenção é produzir uma PSF a partir de P . Dessa forma, uma otimização em pequena escala para restringir a esparsidade da PSF via regularização baseada na

⁸ Este trata-se de um fragmento retangular que contém a informação de interesse.

norma l_1 ⁹ é realizada através da minimização da seguinte função de custo $E(k)$ definida pela Equação 2.14:

$$E(k) = \|\nabla^2 k - \nabla^2 P\|_2^2 + \lambda \|k\|_1 \quad (2.14)$$

no qual k é a PSF da degradação a ser estimada, ∇^2 indica um filtro Laplaciano 3×3 , e λ um escalar para controlar a esparsidade da PSF estimada, o autor do trabalho usou $\lambda = 0.1$ em seus experimentos. O termo de verossimilhança (o primeiro termo) restringe $\nabla^2 k$ a ser semelhante a $\nabla^2 P$, e o termo regularização (o segundo termo) restringe a esparsidade de k . Muitos trabalho fazem uso da norma l_1 na solução desse tipo de problema (NIKOLOVA, 2002; YANG; ZHANG; YIN, 2009; CHAN; DONG; HINTERMULLER, 2010; XU; JIA, 2010). A vantagem de usar a norma l_1 em vez da norma l_2 , também comumente usada, é que esta solução é mais robusta. A norma l_1 é mais robusta que a norma l_2 no sentido de que a mesma é resistente à presença de *outliers* nos dados, ou seja, um pequeno número de *outliers* tem menos influência sobre a solução. Como as arestas e ruídos em uma imagem levam a *outliers*, o termo de regularização l_1 para a estimativa de k torna-se uma boa escolha. Após a estimação da PSF k , a imagem é restaurada utilizando o algoritmo rápido de deconvolução não cega proposto por Cho, Wang e Lee (2011).

Uma limitação presente no trabalho de Hua e Low (2011) é que uma boa restauração realizada sobre a imagem irá depender da precisão da região selecionada pelo usuário, ou seja, do quanto o *highlight* escolhido de fato representa da degradação sofrida pela imagem. Apesar de *highlights* conterem potencialmente informações úteis sobre a degradação da imagem, nem todos os *highlights* presentes na imagem são uma boa representação desta degradação.

Em trabalho por nós publicado (QUEIROZ et al., 2013), propusemos um esquema simples de deconvolução cega para imagens naturais borradas por movimentação de câmera, considerando-se o uso de *highlights* no processo de estimação da PSF do borramento. Consideramos também um borramento uniforme nas imagens. O método foi dividido em três etapas principais:

1. Dada uma imagem borrada de entrada, um mapa binário de *highlights* é gerado utilizando-se o método de detecção automática de reflectância especular proposto por Ortiz e Torres (2006).
2. Usamos o mapa gerado para realizar a segmentação destes *highlights* através de um algoritmo de *matting* denominado *alpha matting* (LEVIN; LISCHINSKI; WEISS, 2008);

⁹ Esta regularização l_1 tem muitas das propriedades benéficas da regularização l_2 , mas produz modelos esparsos que são mais úteis quando usados para restringir a PSF do problema.

3. Selecionamos automaticamente um único *highlight* dentre os segmentados, afim de definir a PSF utilizada posteriormente em um algoritmo de deconvolução não cega proposto por Xu e Jia (2010).

No primeiro passo desse método, definimos como **mapa de *highlights*** a imagem binária resultante do processo de detecção dos *highlights* presentes na imagem degradada original¹⁰. A geração deste mapa foi realizada através do uso de um método automático de detecção de *highlights* proposto por Ortiz e Torres (2006). Considerando $\mathbf{x} = (x, y)$ como a localização de um dado pixel na imagem, uma vez que *highlights* em imagens coloridas apresentam, em geral, altos valores de intensidade $I_{intensity}(\mathbf{x})$ e baixos valores de saturação $S(\mathbf{x})$ ¹¹, quando representadas no modelo HSI, esse método define um processo de limiarização realizado sobre um histograma bidimensional que permite relacionar sinais de intensidade $I_{intensity}$ e saturação S de uma dada imagem colorida, para por fim, identificar *highlights* em uma determinada área do histograma. Sendo assim, o método descarta a informação do matiz H na avaliação do histograma.

Para alcançarmos uma estimativa apropriada da PSF de borramento é necessário realizar uma segmentação que separe de forma precisa os *highlights* do resto da imagem. Uma vez que o método de detecção para a geração do mapa de *highlights* acima não realiza uma segmentação precisa dessas regiões, foi utilizado um algoritmo de *matting* denominado *alpha matting* proposto por Levin, Lischinski e Weiss (2008) para, após detectados o *highlights*, segmentá-los de maneira mais precisa. Nesse método de *matting*, a imagem de entrada I , que é assumida ser uma composição de um primeiro plano (*foreground*) f com um segundo plano (*background*) b , é usada como entrada para o algoritmo. Segundo a Equação 2.15, a cor de um pixel $I(\mathbf{x})$ é então definida como uma combinação linear do primeiro com o segundo plano de tal forma que:

$$I(\mathbf{x}) = \alpha_i f(\mathbf{x}) + (1 - \alpha_i) b(\mathbf{x}) \quad (2.15)$$

em que α_i se refere a opacidade do pixel i de primeiro plano.

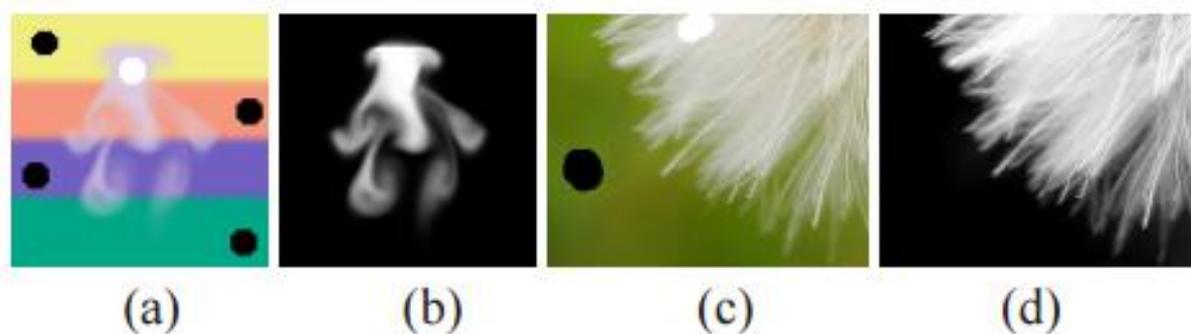
Levin, Lischinski e Weiss (2008) afirmaram que o problema de *matting* torna-se um problema mal posto quando não há a intervenção para indicar regiões de primeiro e segundo planos, sendo assim, em seu trabalho, a identificação dessas regiões é realizada com a ajuda do usuário que realiza marcações manuais na imagem utilizando ferramentas de *scribe*. A Figura 16 mostra dois resultados da aplicação do algoritmo *alpha matting* em

¹⁰ No Capítulo 3 apresentamos um novo método de segmentação para a geração desse mapa (que passará a ser chamado de componente especular da imagem), no qual o mesmo será definido por uma imagem em tons de cinza em vez da binária.

¹¹ Com $I_{intensity}(\mathbf{x}) \in [I_{intensity}(\mathbf{x})_{min}, I_{intensity}(\mathbf{x})_{max}]$ e $S(\mathbf{x}) \in [S(\mathbf{x})_{min}, S(\mathbf{x})_{max}]$, onde $I_{intensity}(\mathbf{x})_{max} = S(\mathbf{x})_{max} = 255$ e $I_{intensity}(\mathbf{x})_{min} = S(\mathbf{x})_{min} = 0$ para o caso da imagem ter uma representação inteira de seus valores ou $I_{intensity}(\mathbf{x})_{max} = S(\mathbf{x})_{max} = 1$ e $I_{intensity}(\mathbf{x})_{min} = S(\mathbf{x})_{min} = 0$ para o caso da imagem ter seus valores escalonados para o intervalo $[0, 1]$.

duas imagens distintas. As marcações em branco feitas pelo usuário indicam o *foreground*, enquanto que as marcações em preto indicam *background*.

Figura 16 – Resultados da aplicação do algoritmo *alpha matting* em duas imagens distintas.



Fonte: Levin, Lischinski e Weiss (2008).

Para cada região do mapa acima definido, um ponto de primeiro plano (interno a região em questão) é obtido na imagem borrada original. Então, uma janela centrada neste ponto é gerada automaticamente. Esta janela irá conter o ponto de primeiro plano selecionado (interno ao reflexo especular), e pontos de segundo plano que residirão em sua borda. Após a definição da janela e de seus pontos de primeiro e segundo planos, o algoritmo *alpha matting* é aplicado para separar o *highlight* da imagem original, gerando assim uma potencial PSF do borramento, não negativa esparsa e de tamanho definido pelo suporte da janela já predefinida.

Por fim, a terceira etapa do método consiste na escolha do menor dentre os *highlights* presentes no mapa para se tornar a PSF do processo de restauração da imagem. O *highlight* foi usado diretamente em um método de deconvolução não cega (XU; JIA, 2010) como a PDF da degradação estimada.

Nesse trabalho, a segmentação grosseira dos reflexos especulares utilizando o método de Ortiz e Torres (2006) seguido do uso do algoritmo *alpha matting*, além de possuir um custo computacional muito alto, produz PSFs com uma quantidade significativa de ruídos, que por sua vez, podem produzir alguns **artefatos de ondulação** na imagem restaurada, uma vez que o processo de restauração de imagens se dá no domínio de frequência. Ademais, o método de seleção automática utilizado no processo de deconvolução usado neste trabalho é feito encolhendo-se o menor dos *highlights* presentes na imagem. O menor *highlight* nem sempre contém as melhores informações sobre a degradação, e esta escolha também favorece à solução da PSF próxima à função generalizada delta de Dirac, que produz uma imagem restaurada se assemelha muito a imagem borrada.

Em outro trabalho, Hu et al. (2014) propuseram um método de restauração de imagens também baseado no uso de *highlights*. Nesse método, a escolha do *highlight* utilizado no processo de estimação da PSF da degradação é feita automaticamente sem a

intervenção do usuário. Os autores propuseram um método de identificação automática de um conjunto de fragmentos na imagem que poderiam ter potencial para serem usados no processo de estimação através de uma série de pre-requisitos tais como:

- Os pixels de um *highlight* devem possuir altos valores de intensidade e deve ser cercado por pixels com baixos valores de intensidade;
- O *highlight* deve aparentar ter uma distribuição esparsa;
- O *highlight* deve ser localizado no centro do fragmento sendo avaliado;
- Não deve haver outras estruturas de imagem em um fragmento contendo um *highlight*.

Após selecionar automaticamente fragmentos que atendam a estes pre-requisitos, um único fragmento é então escolhido com base em uma métrica baseada na densidade espectral dos fragmentos analisados.

Intuitivamente, o melhor *highlight* deve conter uma trajetória de luz bem definida que tem aproximadamente a mesma forma que a PSF da degradação em um fundo relativamente limpo. Apesar de não termos acesso a esta PSF em um problema de deconvolução cega, Goldstein e Fattal (2012) mostraram que podemos obter uma boa aproximação da **densidade espectral** da PSF da degradação diretamente da imagem. Com base nisso, Hu et al. (2014) definiram uma métrica baseada na *densidade espectral* dos fragmentos contendo *highlights* detectados na imagem afim de selecionar automaticamente o melhor *highlight* a ser usado na estimativa da PSF da degradação de imagens naturais. Tal métrica foi definida como segue:

$$d(P, B) = \min_C \|B \otimes \nabla^2 B - C(P \otimes P)\| \quad (2.16)$$

em que B refere-se à imagem borrada, ∇^2 indica um filtro laplaciano, C é um valor constante e P é refere-se a um fragmento contendo um candidato a *highlight* selecionado de acordo com os critério citados acima. Os operadores \otimes e $*$ indicam operações de correlação e convolução, respectivamente. O valor ótimo de C pode ser encontrado resolvendo-se o problema de mínimos quadrados. Dentre todos os fragmentos candidatos, é selecionado aquele P_0 com o menor valor de distância $d(P, B)$, ou seja:

$$P_0 = \arg \min_P d(P, B) \quad (2.17)$$

Após selecionado o melhor candidato P_0 , um método de refinamento deste *highlight* é utilizado para que este possa gerar a PSF estimada da degradação k . Tal qual nos trabalhos apresentados anteriormente, após a estimação da PSF k , a imagem é restaurada utilizando

um algoritmo de deconvolução não cega. Uma vez que este método foi desenvolvido para lidar com imagens de pouca luminosidade e altos nível de saturação, [Hu et al. \(2014\)](#) propôs um método de deconvolução que combina os métodos propostos por [Cho, Wang e Lee \(2011\)](#) e [Whyte, Sivic e Zisserman \(2011\)](#).

[Cho, Wang e Lee \(2011\)](#) propuseram um método que modela *outliers* explicitamente, incluindo pixels saturados, e usou um modelo com abordagem variacional (*Expectation Maximization framework* ([LEVIN et al., 2011](#))) para gerar a imagem restaurada. [Whyte, Sivic e Zisserman \(2011\)](#) propuseram uma modificação do tradicional método de deconvolução de *Richardson-Lucy* (RL) ([LUCY, 1974](#)), com base em um modelo de borramento com uma função de saturação. Contudo, em nossos experimentos, percebemos que um único *highlight* sendo utilizado na estimação da PSF da degradação pode implicar em uma má restauração, uma vez que o *highlight* escolhido pode estar total ou parcialmente saturado, contendo então informação limitada sobre a degradação. Outro problema que percebemos foi que a escolha do melhor *highlight* através da solução da [Equação 2.17](#) favorece a *highlights* que aproximam-se da função generalizada delta de Dirac. *Highlights* com essas características geralmente estão entre os menores *highlights* presentes em uma imagem e estes podem ser encontrados mesmo em imagens borradas.

3 SEGMENTAÇÃO DE REFLEXOS ESPECULARES EM IMAGENS DE ENDOSCOPIA ÓPTICA

Em geral, as imagens obtidas a partir de procedimentos endoscópicos têm um padrão de textura bem definida: eles têm reflexos especulares salientes (causados pela presença de mucosa) distribuídos aleatoriamente ao longo de um fundo rosado/avermelhado parcialmente homogêneo. Como pode ser visto nas imagens da [Figura 17](#), este fundo pode conter informações como vasos, pólipos¹, dobras e outros detalhes pertinentes ao trato gastrointestinal. Mas estes detalhes, embora visíveis em imagens endoscópicas, não são tão salientes como reflexos especulares.

Figura 17 – Mais imagens de endoscopia óptica apresentando reflexos especulares em sua superfície (outras imagens podem ser vistas na [Figura 4](#)).



Fonte: Elaborada pela autora, com imagens extraídas da base disponibilizada por [Bernal, Sánchez e Vilarino \(2012\)](#).

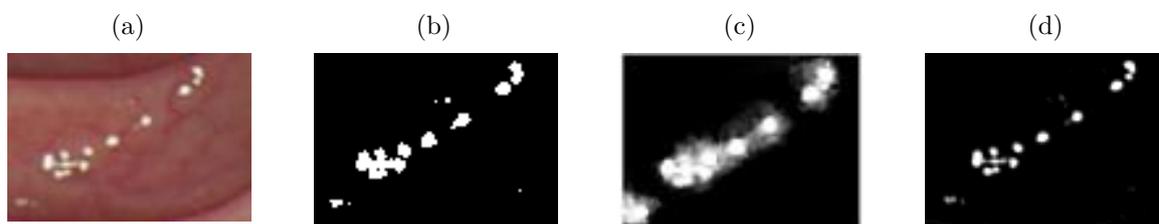
O método de segmentação que propomos neste trabalho tem por base o trabalho por nós publicado e intitulado por “*Automatic Segmentation of Specular Reflections for Endoscopic Images Based on Sparse and Low-Rank Decomposition*” ([QUEIROZ; REN, 2014](#)) e este visa a desenvolver uma separação automática e precisa dos reflexos especulares encontrados em uma imagem de endoscopia óptica, ou seja, em vez de uma máscara binária contendo os reflexos detectados, este método visa a gerar uma máscara em tons de cinza para representar o componente que contém tais reflexos. Na [Figura 18](#) ilustramos um exemplo da segmentação de reflexos realizada utilizando-se um método de detecção grosseira em relação ao método de segmentação precisa proposto por este trabalho ², bem

¹ Pólipos (também chamados de adenomas) referem-se à tumores que ocasionalmente surgem no intestino, resultante de um crescimento anormal das células da mucosa intestinal. Embora a maior parte dessas lesões seja benigna, uma pequena parte delas pode evoluir para malignidade.

² Os termos segmentação precisa e segmentação grosseira foram definidos por nós na [Seção 2.2](#)

como comparamos nosso método de segmentação com a aplicação do algoritmo *alpha matting* (LEVIN; LISCHINSKI; WEISS, 2008) utilizado para realizar a separação de reflexos especulares, em trabalho também nosso, intitulado por “*Image deblurring using maps of highlights*” (QUEIROZ et al., 2013).

Figura 18 – Segmentação grosseira e precisa de reflexos especulares em imagens de endoscopia Óptica: (a) *Zoom* de uma região que contém tais reflexos; (b) Exemplo de segmentação grosseira de reflexos utilizando o método de Arnold et al. (2010); (c) Separação dos reflexos utilizando o algoritmo de *matting* proposto por Levin, Lischinski e Weiss (2008); (d) Exemplo de uma segmentação precisa realizada pelo método que propomos neste trabalho.



Fonte: Elaborada pela autora.

O método aqui apresentado foi desenvolvido com o objetivo principal de extrair reflexos especulares em imagens de endoscopia óptica para que estes possam ser usados posteriormente como ponto de partida para a estimação da PSF de possíveis degradações (borramento) sofridas por essas imagens. Porém, vale salientar que a segmentação destes reflexos é útil não apenas para o propósito de restauração da imagem. Como já foi dito anteriormente na Seção 2.2, estes reflexos podem afetar negativamente a qualidade da imagem. Logo, para muitos procedimentos de análise, que incluem processos como segmentação, reconhecimento de objetos, etc, eles podem se tornar uma fonte de erros (VOGT et al., 2002), uma vez que podem produzir falsas regiões que se tornam um obstáculo para futuras análises dessas imagens.

Propomos um método de segmentação em que, diferentemente da maioria das abordagens citadas na Seção 2.2, não são utilizados limiares com base em valores de intensidades, realizando-se em vez disto, uma decomposição matricial que separa o **componente esparso** (*sparse component*) do **componente de baixo posto** (*low-rank component*) da imagem, através do uso de um algoritmo de PCA Robusto (*RPCA - Robust Principal Component Analysis*) proposto por Ganesh et al. (2009). O componente esparso resultante da decomposição é o que possuirá as informações referentes aos reflexos especulares presentes na imagem.

Algoritmos de RPCA vem sendo bastante utilizados em processos de segmentação devido a sua capacidade de lidar de maneira eficiente com ruídos severos que podem ser encontrados nas imagens (ZHOU et al., 2014; GAN; WANG; WANG, 2012). Na Seção 3.2

explicamos superficialmente o algoritmo utilizado como base do processo de segmentação aqui proposto.

O método de segmentação de reflexos especulares apresentado nesse capítulo pode ser dividido nas seguintes etapas:

1. Aplicação de um filtro de realce na imagem colorida original;
2. Decomposição dos canais verde e azul realçados utilizando o algoritmo de RPCA proposto por [Ganesh et al. \(2009\)](#);
3. União das componentes esparsas resultantes do processo acima gerando assim um único componente esparsa, que por sua vez é modificado a fim de representar apenas as informações de reflexos especulares encontrados na imagem original.

Todas estas etapas do método que aqui propomos podem ser melhor compreendidas pelo Algoritmo 1 e pelo fluxograma apresentado na [Figura 19](#).

Algoritmo 1: Método de segmentação de reflexos especulares em imagens de endoscopia óptica.

Input : Imagem RGB de entrada

Output : Componente esparsa E_{final} contendo apenas os reflexos especulares da imagem de entrada

- 1 $D_{rgb} \leftarrow$ imagem RGB de entrada realçada usando [Equação 3.1](#)
 - 2 $E_g \leftarrow$ solução da [Equação 3.3](#) para $D = D_g$
 - 3 $E_b \leftarrow$ solução da [Equação 3.3](#) para $D = D_b$
 - 4 $E \leftarrow E_g + E_b$
 - 5 $E_{sparse} \leftarrow$ solução da [Equação 3.4](#)
 - 6 $E_{final} \leftarrow$ solução da [Equação 3.6](#)
-

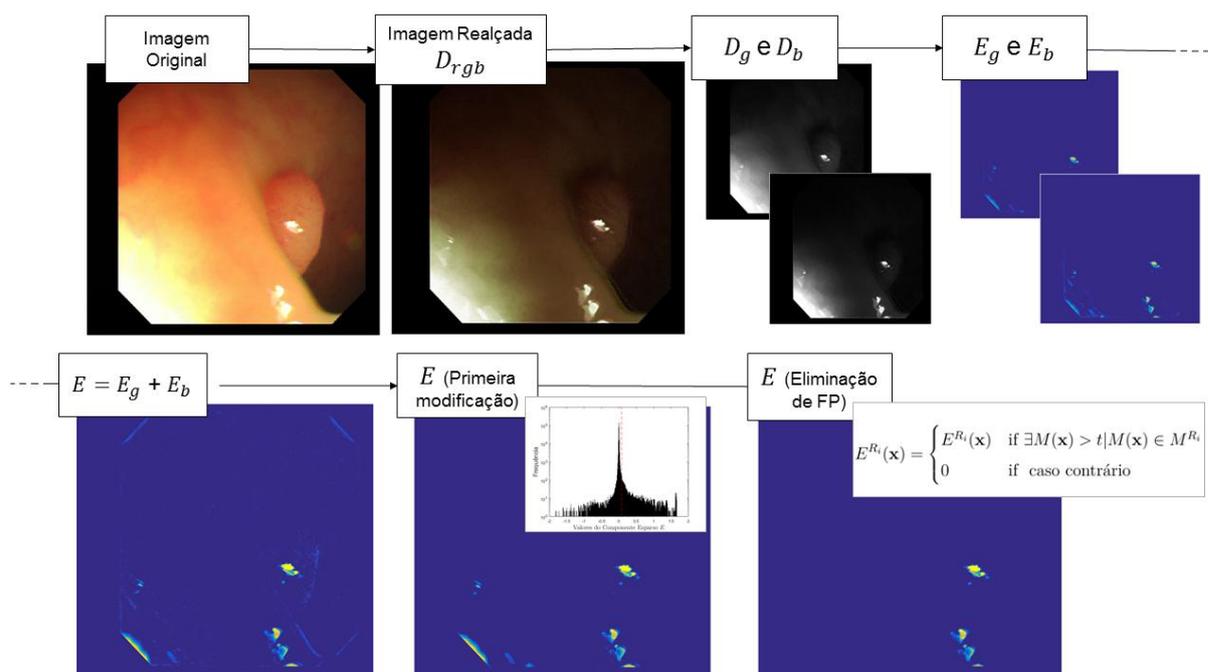
3.1 Realce de Reflexos Especulares

A primeira etapa do processo de segmentação consiste da aplicação de um método de realce nas imagens coloridas originais, cujo objetivo é salientar ainda mais a diferença entre os reflexos especulares e o resto da imagem. Sendo assim, aplicamos um filtro não linear que consiste em multiplicar os planos RGB da imagem colorida original pelo complemento do plano S do modelo de cor HSI . Filtros não lineares aplicam transformações sem o compromisso de manterem o nível médio de cinza da imagem original. Logo:

$$\left[R'G'B' \right]^T = (1 - S) \times \left[RGB \right]^T \quad (3.1)$$

em que R' , G' e B' referem-se aos canais R , G e B da imagem colorida original realçados.

Figura 19 – Fluxograma representando o esquema de segmentação de reflexos especulares em imagens de endoscopia óptica. Da esquerda para a direita, de cima para baixo: Imagem colorida original; Imagem colorida realçada D_{rgb} , canais verde D_g e azul D_b realçados; Componentes esparsas E_g e E_b resultantes da decomposição matricial via RPCA; Componente esparsa $E = E_g + E_b$; Primeira modificação em E através da Equação 3.4; Eliminação de falsos positivos (FP) através da Equação 3.6 e definição da componente especular contendo apenas os reflexos precisamente segmentados;



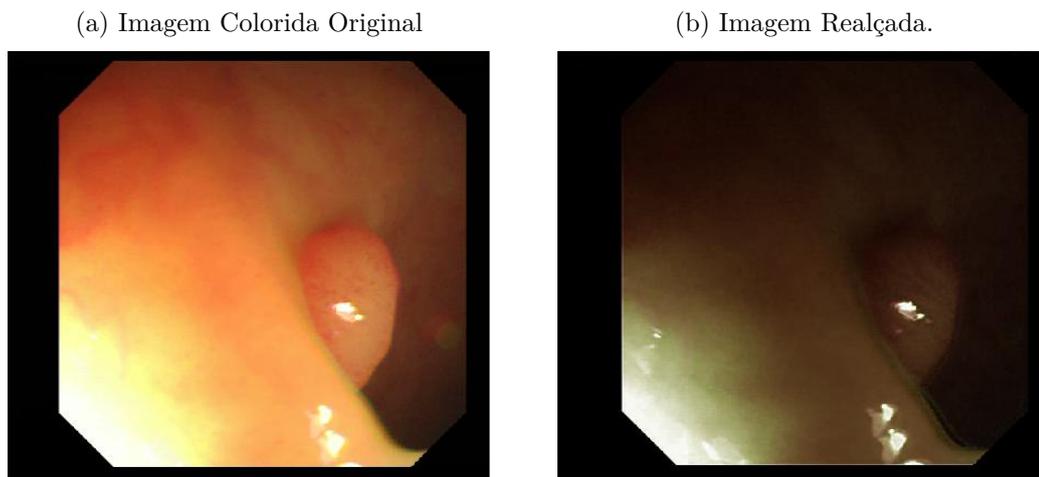
Fonte: Elaborada pela autora.

O efeito dessa transformação é aumentar a diferença entre as regiões mais saturadas da imagens e as regiões menos saturadas, em contrapartida, ela aumenta a diferença entre os reflexos especulares presentes na imagem do restante da mesma. A Figura 20 ilustra o resultado desse processo aplicado à uma imagem de endoscopia óptica. Vamos chamar de $D_{rgb} = [D_r D_g D_b]^T = [R' G' B']^T$ a imagem resultante desse processo de realce.

3.2 Decomposição da Imagem via RPCA

Análise de Componentes Principais (PCA - *Principal Component Analysis*) é uma ferramenta estatística comumente utilizada para encontrar padrões em dados de alta dimensão. Com aplicações em diversas subáreas de processamento de imagens, o PCA oferece uma estimativa otimizada do subespaço quando os dados são corrompidos por ruído Gaussiano suave, porém ele não apresenta um bom desempenho sob condições de dados com muita contaminação, mesmo que esta afete apenas algumas das observações. De acordo com Ganesh et al. (2009), o problema da recuperação de uma matriz de baixo posto

Figura 20 – Realce de reflexos especulares em uma imagem de endoscopia óptica.



Fonte: Elaborada pela autora.

low rank (dados não corrompidos) a partir de uma matriz corrompida arbitrariamente por ruído severo pode ser visto como uma versão robusta do algoritmo de PCA clássico - o RPCA.

Uma vez que imagens endoscópicas são comumente afetadas pela presença de degradações como ruído e reflexos especulares (HEGENBART; UHL; VECSEI, 2011), utilizamos uma variante robusta do tradicional PCA (GANESH et al., 2009) para dividir uma imagem endoscópica de entrada em suas componentes de baixo posto e esparsa. Sendo a componente esparsa aquela que conterá as informações sobre os reflexos especulares presentes na imagem. Uma vez que, dentre os elementos encontrados em imagens endoscópica, os reflexos apresentam-se de maneira mais saliente, a forte distinção entre as regiões de reflexões specular e o segundo plano da imagem é a razão para a utilização bem sucedida do algoritmo de RPCA para detecção destes reflexos.

De acordo com Wright et al. (2009), sob condições gerais, podemos recuperar uma matriz de baixo posto A a partir de uma matriz de entrada $D = A + E$ (no contexto deste trabalho, D pode ser vista como uma imagem em tons de cinza de dimensões $m \times n$.) com erros grosseiros mas escassos E , resolvendo o seguinte problema convexo de otimização:

$$\arg \min_{A,E} \|A\|_* + \lambda|E|_1, \text{ sujeito à } D = A + E. \quad (3.2)$$

em que $\|\cdot\|_*$ representa a norma nuclear de *Schatten*, que por sua vez, se refere à soma dos valores singulares de uma matriz; $|\cdot|_1$ representa a norma l_1 , ou seja, a soma dos valores absolutos de uma matriz; e λ é um parâmetro de peso positivo. Essa otimização é chamada de PCA Robusto (RPCA), uma vez que ela nos permite recuperar corretamente a matriz de baixo posto A dos dados observados, mesmo quando estes dados estão corrompidos por

erro significativo E .

Ganesh et al. (2009) propôs um algoritmo rápido para resolver o problema de otimização apresentado pela Equação 3.2. Nesse algoritmo, eles consideraram a seguinte representação para este problema de otimização:

$$\arg \min_{A,E} \mu \|A\|_* + \mu \lambda |E|_1 + \frac{1}{2} \|D - A - E\|_F^2 \quad (3.3)$$

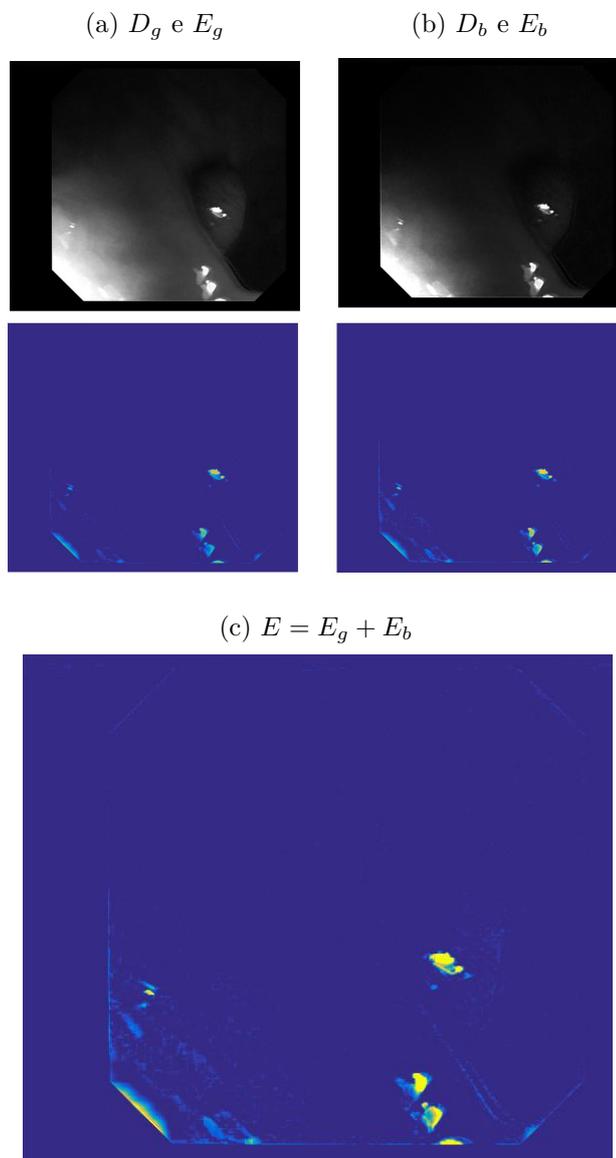
nesse problema, $f(A, B) = \frac{1}{2} \|D - A - E\|_F^2$ penaliza as violações relativas à restrição de igualdade e $\mu > 0$ é definido como um parâmetro de relaxamento. Um vez que $f(A, B)$ é uma função convexa, suave e possui gradiente *Lipschitz* contínuo (com constante de *Lipschitz* igual a 2), o problema de otimização expresso pela Equação 3.3 é então sujeito a uma otimização realizada por um grupo de algoritmos: Os algoritmos de *gradiente proximal*. A explicação em detalhes desse algoritmo foge do escopo deste trabalho, mas pode ser encontrada na obra de Ganesh et al. (2009). Alguns outros métodos de RPCA do estado da arte foram avaliados, porém o método escolhido foi o que melhor atendeu as necessidades impostas pelo contexto. Alguns métodos mais recentes (DING; HE; CARIN, 2011; ARAVKIN et al., 2014) produziam resultados semelhantes ao resultado aqui apresentado, porém, uma vez que estes tinham um custo computacional de execução mais alto, optamos pelo uso do método de Ganesh et al. (2009).

Cores avermelhadas são muito comuns em imagens de endoscopia e, portanto, a intensidade do vermelho próximo da saturação ocorre não apenas em conexão com reflexos especulares, mas em outras regiões da imagem. Devido a este fator, o algoritmo de RPCA utilizado neste trabalho é aplicado separadamente apenas nos canais verde D_g e azul D_b realçados, excluindo-se assim o canal D_r do processo como um todo. Dessa forma, obtemos:

$$D_g = A_g + E_g \quad \text{e} \quad D_b = A_b + E_b$$

A componente esparsa gerada após esse processo é definida por $E = E_g + E_b$. A Figura 21 mostra o resultado desse processo. Nesta figura são apresentados os canais D_g e D_b , suas respectivas componentes esparsas E_g e E_b e por fim, a componente esparsa E . Vale observar que as componentes esparsas são exibidas utilizando um mapa de cores azul-amarelo em detrimento de uma imagem em tons de cinza, esse mapa de cor foi escolhido para facilitar a compressão do leitor. Tons mais próximos do amarelo indicam valores mais altos (geralmente proveniente de reflexos especulares ou regiões de com altos valores de intensidade) e os tons em azul indicam valores mais baixos. No decorrer deste trabalho, este mapa de cor azul-amarelo será utilizado com frequência para indicar esta componente esparsa E .

Figura 21 – Componente esparsa E resultante da decomposição matricial utilizando RPCA.



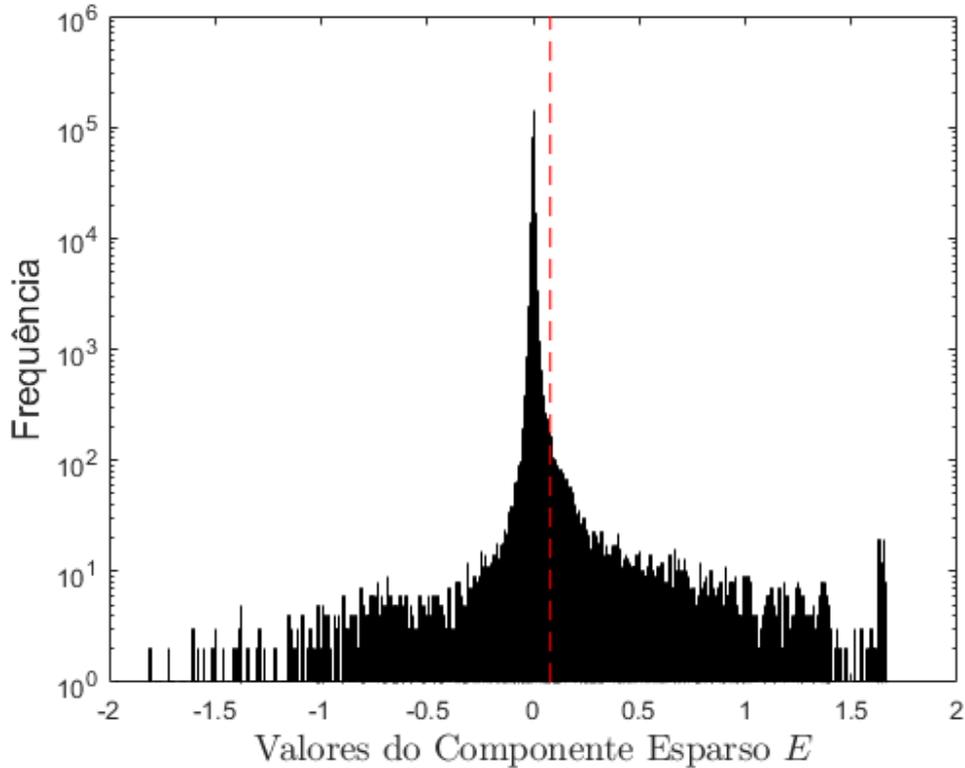
Fonte: Elaborada pela autora.

3.3 Segmentação dos Reflexos especulares: Definição da Componente Esparsa da Imagem

Devido aos padrões de textura bem definidos, a componente esparsa E resultante da operação anterior tem um comportamento bem definido: valores de alta intensidade (característica relevante das regiões de reflexão especular) e valores de intensidade mais baixos, provenientes de regiões menos proeminentes na imagem, como por exemplo, bordas que delimitam objetos como vasos, dobras no tecido, etc. A Figura 22 mostra o histograma da componente E resultantes do processo de RPCA e exibida na Figura 21c. Nesse histograma, o eixo referente à frequência é exibido em escala logarítmica afim de facilitar

a compreensão do leitor.

Figura 22 – Histograma do componente esparsa E . A linha tracejada em vermelho se refere ao valor de $s(E)$.



Fonte: Elaborada pela autora.

A linha tracejada em vermelho no histograma da [Figura 22](#) refere-se ao valor do desvio padrão $s(E)$ da amostra E . Considerando a localização espacial de um dado pixel $\mathbf{x} = (x, y)$ em E , é possível gerar uma versão ainda mais esparsa de E convertendo para zero todos os $E(\mathbf{x})$ cujos os valores sejam menores ou igual a $s(E)$. A [Equação 3.4](#) nos mostra como essa componente mais esparsa de E pode ser calculada e a [Figura 23b](#) mostra esta versão de E , definida como E_{sparse} resultante desse processo.

$$E_{sparse}(\mathbf{x}) = \begin{cases} E(\mathbf{x}) & \text{if } E(\mathbf{x}) > s(E) \\ 0 & \text{if caso contrário} \end{cases} \quad (3.4)$$

Durante experimentos, percebemos que algumas regiões com altos valores de intensidade na imagem são confundidos com reflexos especulares pelo algoritmo apresentado até agora. Em particular, a superfície da mucosa na proximidade da câmara pode aparecer muito iluminada e, portanto, essas regiões podem ser erroneamente segmentadas pelo algoritmo de detecção. A [Figura 21c](#) ilustra um exemplo onde a região da imagem localizada no canto inferior esquerdo é segmentada erroneamente como reflexo especular por possuir

altos valores de intensidade. Para resolver este problema, fizemos uso da propriedade de que a região de imagem ao redor do contorno de reflexos especulares geralmente apresenta uma forte distinção com o fundo da imagem. Sendo assim, definimos um limiar t com base na magnitude do gradiente da imagem colorida original $M = |\nabla D_{rgb}|$:

$$t = \left(\frac{\overline{M} + s(M)}{\overline{M}} \right)^{-1} \quad (3.5)$$

em que \overline{M} refere-se a média dos valores de intensidade de M e $s(M)$ refere-se ao desvio padrão da mesma amostra.

O início do processo de eliminação desses falsos positivos se dá com a criação de uma máscara binária a partir de E_{sparse} através de uma simples detecção de componentes conexos considerando-se 8 vizinhos. Essa máscara pode ser então definida pelo conjunto de n fragmentos de imagem contendo as regiões disjuntas $\mathbb{R} = \{R_i\}_{i=1}^n$. O conjunto $\mathbb{E}^{\mathbb{R}} = \{E_{sparse}^{R_i}\}_{i=1}^n$ refere-se então ao conjunto de todos os fragmentos de E_{sparse} equivalentes a cada região R_i da máscara binária. Dessa forma, o elemento $E_{sparse}^{R_i}$ é então o i -ésimo conjunto de valores de intensidade em E_{sparse} relacionado à região R_i . Uma vez que M representa a magnitude do gradiente da imagem original D_{rgb} , $\mathbb{M}^{\mathbb{R}} = \{M^{R_i}\}_{i=1}^n$ refere-se ao conjunto de fragmentos em M referente a cada região R_i . No processo de eliminação de falsos positivos, para cada região R_i , nós checamos se existe ao menos um elemento $M(\mathbf{x})$ em M^{R_i} cujo valor de intensidade é maior que o limiar t . Se essa condição não for satisfeita, todos os valores de intensidade do conjunto $E_{sparse}^{R_i}$ são convertidos para zero. A Equação 3.6 mostra a formalização desse procedimento. Chamaremos de $E_{final}^{R_i}$ o i -ésimo conjunto de valores de intensidade na componente E_{sparse} após a remoção dos falsos positivos.

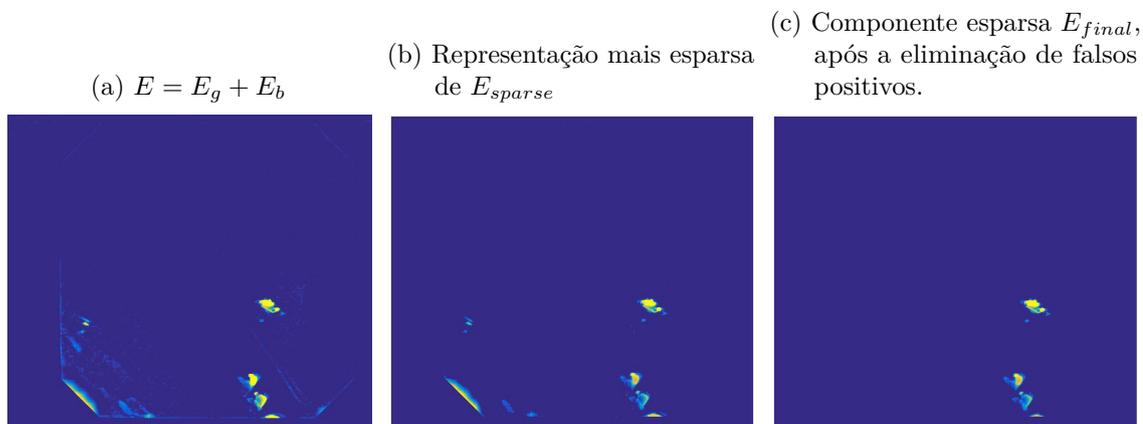
$$E_{final}^{R_i}(\mathbf{x}) = \begin{cases} E_{sparse}^{R_i}(\mathbf{x}) & \text{if } \exists M(\mathbf{x}) > t | M(\mathbf{x}) \in M^{R_i} \\ 0 & \text{if caso contrário} \end{cases} \quad (3.6)$$

A Figura 23c mostra a componente esparsa final E_{final} após o processo de eliminação de falsos positivos. Esta nova componente esparsa passa então a ser chamada de **componente especular** da imagem D_{rgb} . A componente de baixo posto reformulada $A = D_{rgb} - E_{final}$ é chamada então de **componente difusa** da imagem.

A Figura 24 apresenta alguns resultados da segmentação precisa de reflexos especulares proposta neste trabalho. Mais resultados são mostrados na Capítulo 5. Nos experimentos que validam o método aqui proposto em comparação com alguns outros métodos do estado da arte apresentamos também tempos de execução e valores de parâmetros do algoritmo de RPCA utilizado.

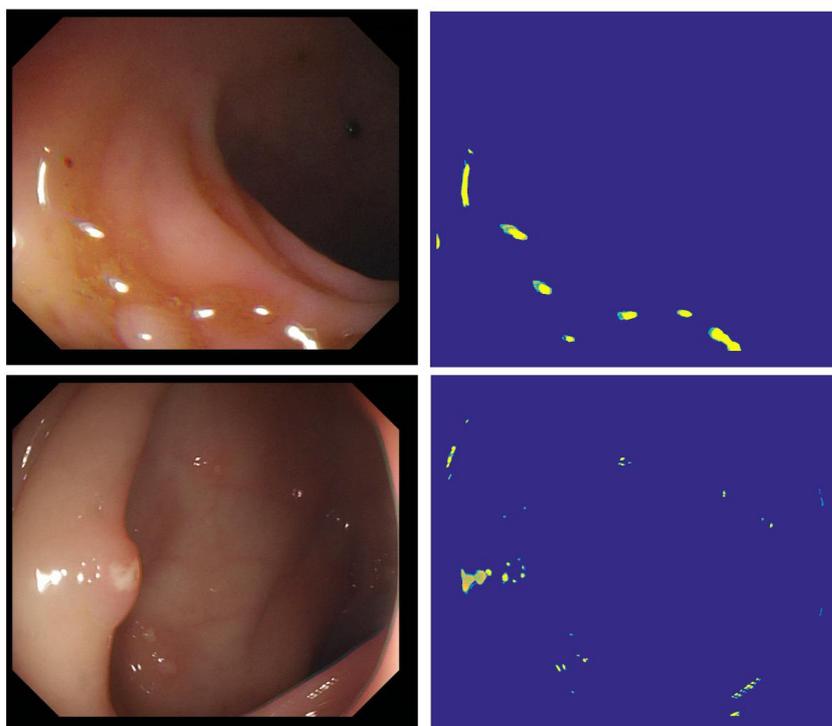
Por simplicidade de notação, no decorrer deste trabalho, o termo E_{final} será referido

Figura 23 – Definição da componente esparsa E_{final} a partir da imagem realçada D_{rgb} da Figura 20a. Tal componente é representada por uma máscara em tons de cinza que contém apenas os reflexos especulares presentes na imagem.



Fonte: Elaborada pela autora.

Figura 24 – Alguns resultados do método proposto de segmentação de reflexos especulares em imagens de endoscopia óptica. Da esquerda para a direita: Imagem colorida original e a componente especular E_{final} .



Fonte: Elaborada pela autora.

apenas como E . Sendo assim, vamos redefinir aqui o conjunto de n fragmentos de imagem contendo as regiões disjuntas $\mathbb{R} = \{R_i\}_{i=1}^n$ de $E = E_{final}$. Vale esclarecer, também que nesse caso, daqui em diante, todas as menções ao conjunto $\mathbb{E}^{\mathbb{R}}$ irá referir-se todos os elementos E^{R_i} presentes em $E = E_{final}$.

4 RESTAURAÇÃO DE IMAGENS ENDOSCÓPICAS UTILIZANDO REFLEXOS ESPECULARES

Como mostramos na Seção 2.5, trabalhos recentes do estado da arte fazem uso de *highlights* (que podem incluir reflexos especulares) no processo de restauração de imagens (HUA; LOW, 2011; QUEIROZ et al., 2013; HU et al., 2014; LIU et al., 2016), principalmente quando estas são capturadas sob condições de pouca luz, resultando em imagens com pouca iluminação e/ou saturadas. Tais trabalhos tendem a estimar a PSF de degradação levando-se em consideração esses fatores, diferentemente de outros métodos de deconvolução cega, que descartam a influência de regiões saturadas durante a estimação da PSF. Nesse caso, as regiões saturadas referem-se aquelas provocadas por situações na qual a luminosidade da cena excede o alcance do sensor da câmera. Imagens com *pixels* saturados tendem a ser restauradas com efeito colateral de muitos artefatos de ondulação quando esta restauração é realizada utilizando-se métodos clássicos de deconvolução cega, que não consideram tais *pixels*. Em seu trabalho, Whyte, Sivic e Zisserman (2011) mostraram o artefato de ondulação é causado pela tentativa de estimar os valores de pixels que são mais brilhantes do que a saída máxima do sensor.

Apresentamos aqui um método de restauração de imagens endoscópicas borradas por movimento, onde a PSF da degradação é estimada através do agrupamento e fusão de *highlights* em forma de reflexos especulares presentes nessas imagens.

4.1 Estimação da Degradação Através de *Highlights*

Em trabalho publicado e intitulado por “*Image Deblurring Using Maps of Highlights*” (QUEIROZ et al., 2013), apresentamos um modelo que justifica do uso de *highlights* no processo de restauração de uma imagem. Esta seção dedica-se a apresentação deste modelo. Voltamos aqui a utilizar o termo “*highlights*” em vez de “reflexos especulares”, pois o modelo desenvolvido neste trabalho considera não apenas reflexos especulares, mas também pequenos pontos de luz encontrados em imagem.

Na Equação 4.1, o sinal borrado B_h contem um *highlight* representado pelo pico h . Neste caso, B_h foi criado através da convolução de um sinal original não borrado I_h com

uma PSF k (Ver Figura 25a).

$$B_h = I_h * k \quad (4.1)$$

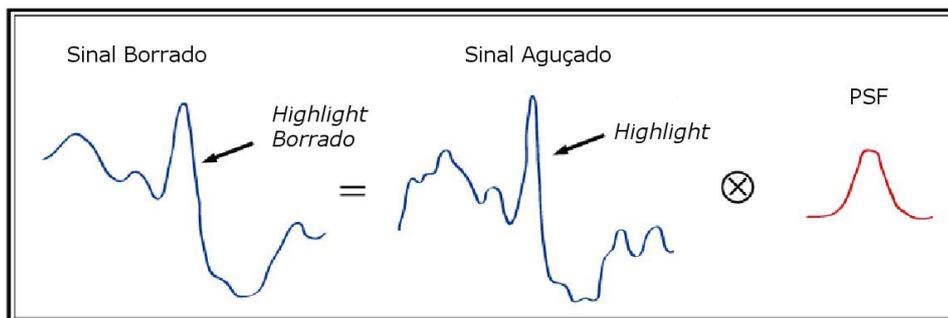
Dado o sinal borrado B_h , é possível encontrar uma separação que satisfaça:

$$B_h = B_{-h} + h \quad (4.2)$$

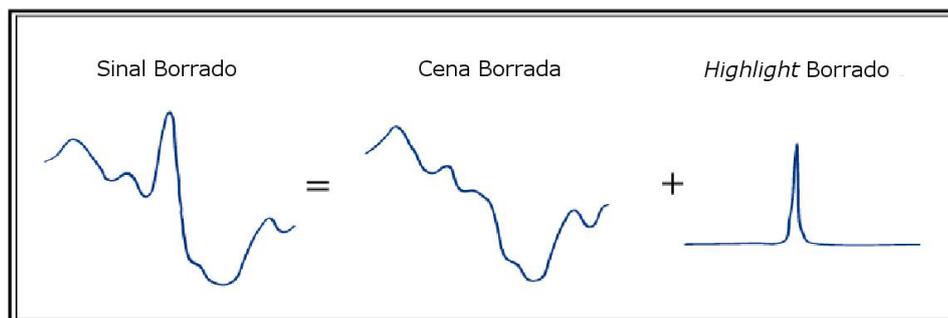
em que B_{-h} equivale ao sinal borrado sem a presença do *highlight* h (ver Figura 25b). Ou seja, o sinal pode ser separado em um sinal borrado de baixa frequência e um *highlight* borrado.

Figura 25 – Perfil 1-D de um sinal borrado.

(a) Perfil 1-D de um sinal borrado que contém um *highlight*.



(b) O sinal pode ser separado em um sinal borrado de baixa frequência e um *highlight* borrado.



Fonte: Elaborada pela autora.

Uma vez que a energia luminosa de um *highlight* presente em uma imagem nítida é concentrada em uma região compacta, ela pode ser aproximada por uma função generalizada *Delta de Dirac* $\delta_{(p,q)}$, definida pela Equação 4.3. Em razão de suas propriedades contraditórias, o *Delta de Dirac* não trata-se necessariamente de uma função, mas de uma

distribuição, por isso é chamada também de função generalizada.

$$\delta_{(p,q)}(x, y) = \begin{cases} 1 \times \infty, & \text{se } x = p \text{ e } y = q \\ 0, & \text{caso contrários} \end{cases} \quad (4.3)$$

com

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F_s(x, y) \delta(x - p, y - q) dx dy = F_s(p, q)$$

Portanto, o sinal borrado B_h pode ser aproximado por uma convolução da PSF da degradação k com a soma da imagem sem a presença de *highlights* I_{-h} e o impulso δ (ver Figura 26a):

$$B_h \approx [I_{-h} + \delta_{(p,q)}] * k \quad (4.4)$$

Substituindo B_h da Equação 4.2 na Equação 4.4, obtemos:

$$B_{-h} + h \approx [I_{-h} + \delta_{(p,q)}] * k \approx (I_{-h} * k) + (\delta_{(p,q)} * k) \quad (4.5)$$

Finalmente, podemos concluir a partir da Equação 4.5 que o *highlight* borrado h pode então ser aproximado pela convolução entre um impulso $\delta_{(p,q)}$ e a PSF k (ver Equação 4.6), que por sua vez, equivale a própria PSF k . Sendo assim, podemos representar a PSF dos sistema de degradação a partir de *highlights* presentes na imagem borrada.

$$h \approx \delta_{(p,q)} * k \approx k \quad (4.6)$$

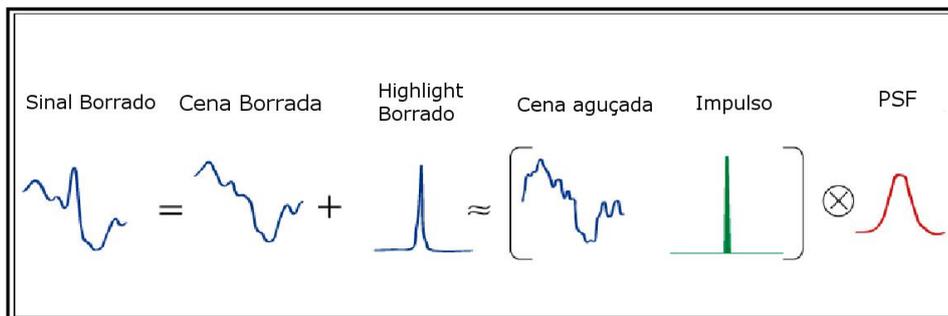
4.2 Restauração de Imagens Endoscópicas Baseada no Agrupamento e Fusão de Reflexos Especulares

Como pudemos observar na Seção 2.5, os métodos de restauração de imagens baseado no uso de *highlights* para estimar a PSF da degradação valem-se, no geral da intervenção do usuário na escolha do *highlight* usado nesse processo, ou da escolha automática de um único *highlight* presente na imagem. Diferente dos métodos presentes no estado da arte, o método aqui proposto estima a PSF da degradação através do agrupamento e fusão dos *highlights* em forma de reflexos especulares presentes em imagens de endoscopia óptica. Partimos da hipótese que uma vez agrupados por similaridades espaciais e de intensidade e uma vez fundidos, estes reflexos podem trazer informações mais ricas sobre o processo de degradação.

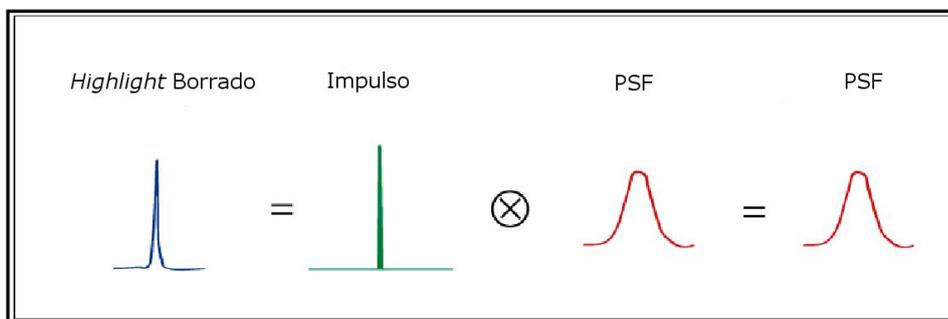
Um trabalho recente no estado da arte (MAI; LIU, 2015) mostram o uso da fusão de PSFs geradas por diversos métodos de estimação. Segundo Mai e Liu (2015), a fusão

Figura 26 – Continuação das ilustrações da Figura 25.

- (a) O *highlight* geralmente é concentrado em uma região compacta. Logo, podemos idealizá-lo como um impulso (δ). Nesse caso, o sinal borrado pode ser aproximado por uma convolução entre a PSF k e a soma do impulso δ com I_{-h} .



- (b) O *highlight* borrado que foi separado da imagem borrada é também uma estimativa para a função de degradação.



Fonte: Elaborada pela autora.

de várias PSFs estimadas usando diferentes métodos, em uma PSF mais precisa que pode trazer melhores resultados no processo de restauração da imagem do que cada PSF individual. A ideia básica por trás deste trabalho é a de que as PSFs geradas por diversos métodos do estado da arte muitas vezes se complementam, uma vez que possuem similaridades em suas formas. Estendemos, portanto esta ideia, afirmando que *highlights* com características espaciais similares também se complementam.

Uma vez que provamos a eficácia do uso de *highlights* no processo de estimação da degradação sofrida por um sinal (ver Seção 4.1), propomos aqui um novo método de restauração onde a PSF da degradação é estimada pelo seu agrupamento e fusão. Os métodos de agrupamento e fusão propostos nesta tese são simples e possuem um custo computacional baixo, mesmo lidando com uma grande quantidade de reflexos especulares. O agrupamento de reflexos precede o método de fusão, pois nem sempre, um dado reflexo contém informações precisas sobre a degradação, isso se dá devido a vários fatores como tamanho, saturação e ruídos encontrados neste reflexo. Logo, o agrupamento prévio tende a gerar PSFs em potencial fundidas a partir de reflexos com propriedades espaciais, de forma e de intensidade semelhantes, ou seja, apenas subgrupos de reflexos especulares

podem complementar-se a fim de gerar uma boa estimativa da degradação sofrida pela imagem.

O processo de restauração que propomos nesta tese pode ser dividido nas seguintes etapas:

1. Um novo método de segmentação precisa de reflexos especulares em imagens de endoscopia óptica (já apresentado por nós no [Capítulo 3](#));
2. Aplicação de um novo método de agrupamento não supervisionado (baseado no algoritmo FCM - *Fuzzy C-Means Clustering*) sobre os reflexos segmentados de acordo com suas características espaciais, de forma e de intensidade (Subseção [4.2.1](#) e Subseção [4.2.2](#));
3. Um novo método de fusão dos reflexos especulares pertencentes a cada grupo como forma de gerar o que chamaremos de **PSFs em potencial** para o processo de restauração (Subseção [4.2.3](#));
4. A escolha automática da melhor PSF em potencial é realizada utilizando-se a métrica proposta por [Hu et al. \(2014\)](#) a apresentada pela [Equação 2.16](#).
5. A estimação da PSF k com base na PSF em potencial escolhida no processo anterior.
6. O uso de um método de deconvolução não-cega, para encontrar uma imagem nítida a partir da PSF k estimada.

Todas estas etapas podem ser melhor compreendidas pelo fluxograma do método aqui proposto apresentado na [Figura 27](#).

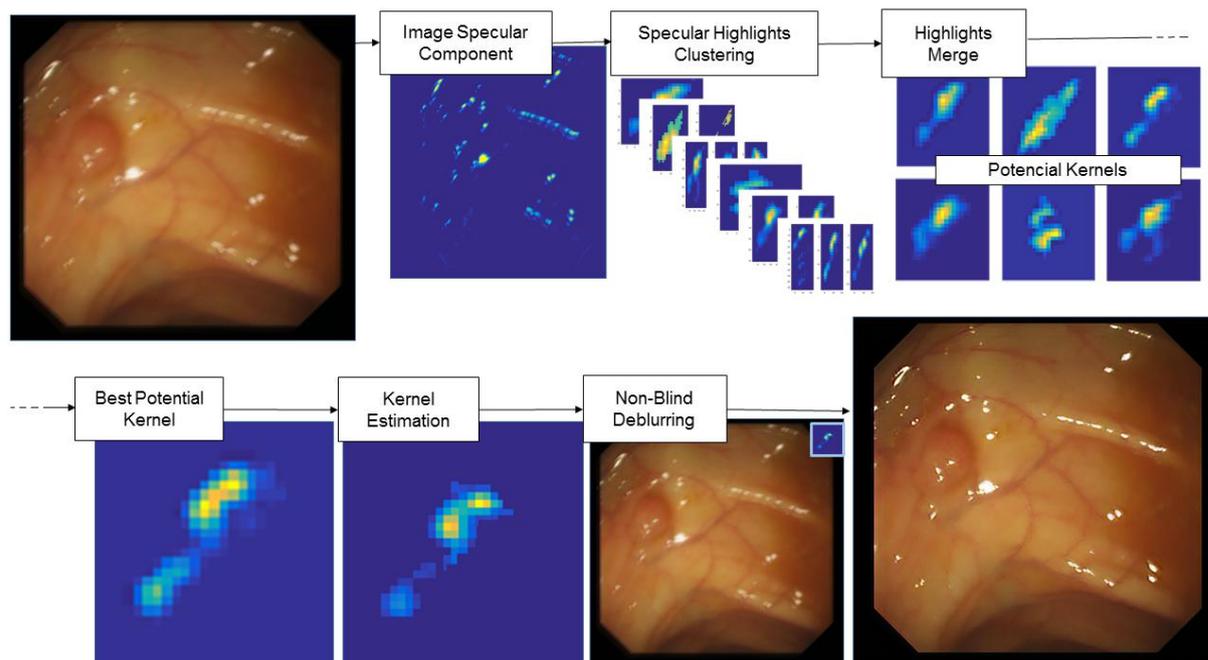
4.2.1 Extração de Características

A proposta desta etapa de extração de características é capturar **informações de forma** e **informações espaciais** das regiões de reflexos especulares representados pelo conjunto \mathbb{R} e **informações de valores de intensidade** dos dos reflexos especulares representados pelo conjunto $\mathbb{E}^{\mathbb{R}}$. Uma vez que tais características são extraídas, é possível verificar quais reflexos contêm ou não informações úteis sobre a degradação. O método de extração de características implementado foi pensado para lidar rapidamente com um número relativamente grande de reflexos que pode haver na imagem¹. No total, seis características são extraídas dos reflexos presentes em E .

Logo, como podemos ver na [Figura 28](#), para cada $R_i \in \mathbb{R}$ foram extraídas duas características de forma e três características espaciais, enquanto que para cada E^{R_i} foi extraída uma característica relacionada à intensidade.

¹ A maior parte das imagens apresentam cerca de 15 a 40 reflexos, porém muitas apresentam valores acima de 100 reflexos.

Figura 27 – Fluxograma representando o esquema proposto de restauração de imagens endoscópicas: Da esquerda para a direita, de cima para baixo: Imagem degradada original; máscara contendo os reflexos especulares precisamente segmentados, agrupamento de reflexos especulares, fusão de reflexos especulares gerando as PSFs em potencial do sistema; seleção da melhor PSF em potencial; estimação da PSF da degradação a partir da etapa anterior; restauração da imagem através de um processo de deconvolução não cega utilizando a PSF estimada na etapa anterior; imagem restaurada.



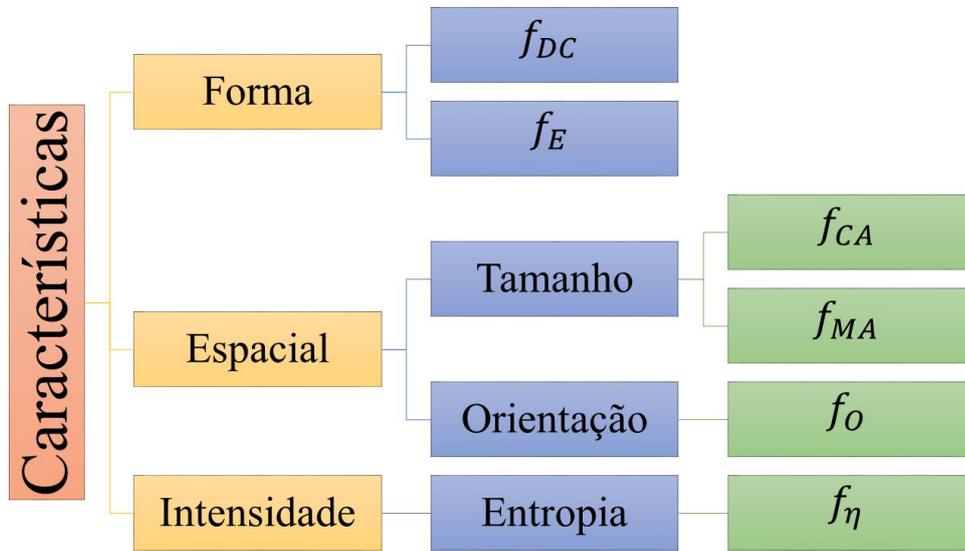
Fonte: Elaborada pela autora.

Vale observar aqui que, uma vez que a PSF da degradação de uma imagem é esparsa e possui um pequeno tamanho com relação a imagem degradada (LEVIN et al., 2009), nós eliminamos dos processo descritos a partir daqui, os reflexos especulares muito grandes encontrados na imagem. Para tanto, com base em observações empíricas, definimos um limiar com base nas dimensões do fragmento de E que contém o reflexo segmentado, eliminando portanto dos conjuntos \mathbb{R} e $\mathbb{E}^{\mathbb{R}}$, todos aqueles cujas dimensões sejam maiores que 15% das dimensões da imagem². Uma vez que PSFs muito pequenas aproximam-se da função delta e favorecem resultados com imagem restaurada ainda borrada, PSF demasiadamente pequenas também são eliminadas. Neste trabalho, eliminamos todos os *patches* com dimensões menores do que 2% das dimensões da imagem, tal valor foi definido também empiricamente.

A primeira característica extraída a partir de cada R_i é chamada de f_{DC} , e esta se trata do componente DC da Transformada Discreta de Cosseno (*Discrete Cosine*

² Observamos, qua na maior parte dos casos, *patches* de tamanho acima de 15% das dimensões da imagem contém *highlights* grandes demais para conseguir representar uma PSF de degradação da imagem.

Figura 28 – Características extraídas dos reflexos especulares presentes na componente especular E .



Fonte: Elaborada pela autora.

Transform - DCT). A DCT tem uma forte propriedade de compactação de energia, permitindo que toda a informação de forma possa ser resumida em alguns coeficientes. A definição da DCT 2-D para uma matriz de entrada P^{in} (com dimensões $M \times N$) e uma matriz de saída P^{out} é definida pela [Equação 4.7](#):

$$P_{pq}^{out} = \alpha_p \alpha_q \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} P_{mn}^{in} \cos \frac{\pi(2m+1)p}{2M} \cos \frac{\pi(2n+1)q}{2N} \quad (4.7)$$

em que $0 \leq p \leq M-1$, $0 \leq q \leq N-1$,

$$\alpha_p = \begin{cases} \frac{1}{\sqrt{M}}, & \text{if } p = 0 \\ \sqrt{\frac{2}{M}}, & \text{if } 1 \leq p \leq M-1 \end{cases}$$

e

$$\alpha_q = \begin{cases} \frac{1}{\sqrt{N}}, & \text{if } q = 0 \\ \sqrt{\frac{2}{N}}, & \text{if } 1 \leq q \leq N-1 \end{cases}$$

para o nosso caso, P^{in} refere-se ao fragmento R_i . O valor da característica f_{DC} refere-se à componente DC do fragmento de saída P^{out} .

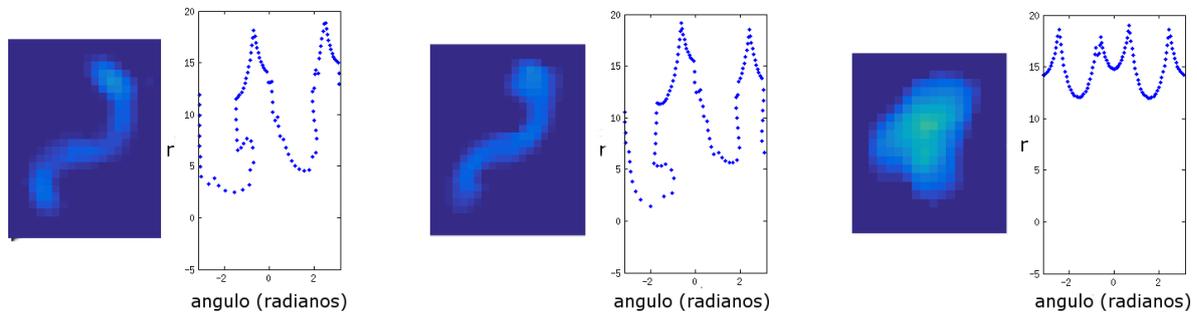
Uma assinatura é a representação 1-D da borda de um objeto (nesse caso, cada objeto é uma região que representa um reflexo especular na nossa componente especular). Em assinaturas, nós podemos definir a distância r a partir do centroide de um objeto para a borda em função de ângulos (em radianos). A [Figura 29](#) apresenta exemplos de assinaturas relativas a alguns reflexos especulares presentes em uma imagem de endoscopia

ótica. Computamos a assinatura A_i de cada região $R_i \in \mathbb{R}$, e para tornar nosso algoritmo robusto a rotações dos objetos contidos nesse mapa, computamos a Transformada rápida de Fourier (*Fast Fourier Transform*- FFT) destas assinaturas. Por fim, usamos como característica de forma f_E , a densidade espectral desse sinal transformado, ou seja, para cada $R_i \in \mathbb{R}$, f_E é definida de acordo com a [Equação 4.8](#):

$$f_E = |\hat{A}_i(\omega)|^2 \quad (4.8)$$

onde \hat{A}_i refere-se a FFT aplicada sobre a assinatura do sinal R_i e ω é a coordenada no domínio de frequência.

Figura 29 – Reflexos especulares com formas semelhantes possuem assinaturas semelhantes.



Fonte: Elaborada pela autora.

O valor da área convexa f_{CA} de uma região R_i foi usada como nossa primeira característica referente a tamanho. Este se refere ao número de pixels contidos no casco convexo referente a esta região, que por sua vez é definido pelo menor polígono convexo que contém a região em R_i . A [Figura 30](#) ilustra o exemplo de uma região com forma irregular e seu casco convexo.

Figura 30 – Região com forma irregular (à esquerda) e seu casco convexo (à direita).

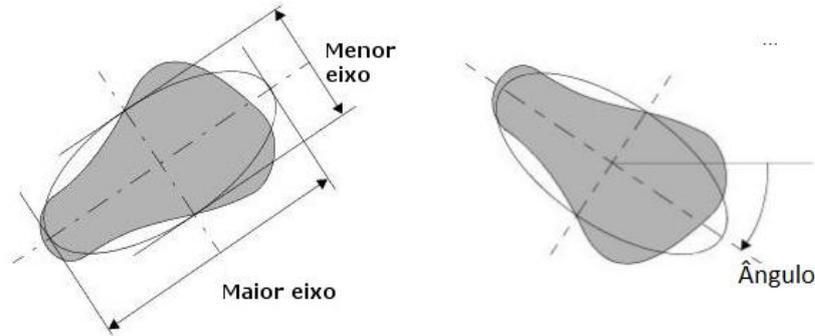


Fonte: Elaborada pela autora.

O valor f_{MA} define nosso segundo descritor de tamanho. Este valor refere-se ao comprimento do maior eixo da elipse que engloba uma dada região R_i e cujo segundo

momento central (ou simplesmente variância) normalizado é igual ao da região em questão. A característica de orientação f_O a também extraída é definida como o ângulo entre o eixo horizontal e o maior eixo da elipse que engloba a região mencionado acima. Na Figura 31 ilustramos o maior eixo da elipse e a orientação da mesma, que por sua vez equivalem aos descritores f_{MA} e f_O .

Figura 31 – Ilustrações dos descritores f_{MA} (à esquerda) e f_O (à direita) de uma região.



Fonte: Elaborada pela autora.

Entropia é uma medida estatística comumente usada na caracterização de texturas em imagens digitais e para os propósitos deste trabalho, a entropia pode ser definida como segue:

$$f_\eta = - \sum E^{R_i} \log_2(E^{R_i}) \quad (4.9)$$

Por fim, como característica de intensidade, nós fazemos uso do valor de entropia f_η de cada reflexo especular E^{R_i} .

4.2.2 Agrupamento de Reflexos Especulares

Como resultado do processo de extração de características aplicado sobre os conjuntos \mathbb{R} e $\mathbb{E}^{\mathbb{R}}$, o conjunto $\mathbb{F} = \{F_i\}_{i=1}^n$ pode ser obtido. Dessa forma, cada elemento $F_i = \{f_{DC}, f_E, f_{CA}, f_{MA}, f_O, f_\eta\}$ refere-se as características extraídas de cada reflexo especular em E .

O processo de análise de agrupamento (*partitionial cluster analysis*) pode ser visto como o problema de particionar um conjunto de objetos que compartilham características similares em grupos (*clusters*). Um algoritmo de agrupamento amplamente utilizado é o *Fuzzy C-Means* (FCM) (BEZDEK, 1981). Diferentemente de outro algoritmo também bastante conhecido, o *k-means* (HARTIGAN; WONG, 1979), o FCM permite que um determinado objeto pertença a dois ou mais grupos após o particionamento dos dados. Nesta tese, nós desenvolvemos um método de agrupamento baseado no FCM sobre o conjunto \mathbb{F} . Uma vez que n refere-se ao número de reflexos especulares em E , esse procedimento

visa agrupar esses reflexos em m grupos $\mathbb{C} = \{C_j\}_{j=1}^m$, com $m \leq n$. Dessa forma, o FCM gera valores μ_{ij} que são definidos como o grau de pertencimento (o valor de probabilidade entre 0 e 1) de $F_i \in C_j$. Assim, para um dado elemento F_i , a soma de todos os valores μ_{ij} para todos os grupos C_j é 1:

$$\sum_{j=1}^m \mu_{i,j} = 1, \forall F_i \in \mathbb{F} \quad (4.10)$$

Neste trabalho, o número inicial de grupos m é calculado de acordo com o número de reflexos presente na imagem. De acordo com experimentos, este foi definido como $m = \lfloor n/5 \rfloor^3$. Inicialmente, nossa ideia resumia-se a uma única execução do algoritmo FCM sobre o conjunto \mathbb{F} e, para cada elemento F_i , escolher o grupo C_j cujo valor de μ_{ij} fosse máximo. Porém, uma vez que o FCM inicia todos os valores μ_{ij} de forma aleatória, o mesmo pode produzir grupos com número de elementos diferentes quando executado mais de uma vez sobre um mesmo conjunto de dados, ou seja, uma mesma imagem.

Para melhorar a consistência do resultado de agrupamento, o algoritmo FCM foi executado várias vezes e o resultado desses agrupamentos armazenados. De acordo com experimentos, chegamos a conclusão de que executar o algoritmo 30 vezes já produz um resultado consistente. Após as execuções do FCM, a definição da pertinência de cada reflexo (representado por cada elemento F_i) a um determinado grupo C_j foi atualizada da seguinte forma: Primeiramente, para cada execução do FCM, procura-se pelo grupo C_j^l ao qual este reflexo F_i foi associado pela escolha do valor máximo de μ_{ij} . Neste caso o índice l irá se referir à l -ésima execução do FCM, com $1 \leq l \leq 30$ ⁴. Em seguida, de posse de todos os grupos procurados, faz-se a intersecção entre os elementos desses grupos:

$$C'_j = \bigcap_{l=1}^{30} C_j^l \quad (4.11)$$

o resultado dessa intersecção definirá o novo grupo C'_j que conterá o reflexo F_i em questão. Esse procedimento é realizado para todo $F_i \in \mathbb{F}$. O Algoritmo 2 mostra o método de agrupamento que estamos propondo, com base no agrupamento FCM. Por simplicidade de notação, o termo C'_j será referido apenas como C_j no decorrer deste trabalho.

Para entendermos melhor este processo, vamos observar a [Figura 32](#) em que ilustramos o resultado da aplicação desse método de agrupamento sobre uma imagem contendo $n = 18$ reflexos especulares, após o processo de segmentação e eliminação de reflexos demasiadamente grandes e pequenos. A imagem, bem como sua PSF real de

³ $\lfloor x \rfloor$ é equivalente ao valor inteiro mais próximo de x .

⁴ Vale observar que em nossa formalização do problema, l refere-se a um valor inteiro de *index* e não a um valor de potência.

Algoritmo 2: Método de agrupamento proposto desenvolvido com base no FCM.

Input : $\mathbb{F} = \{F_i\}_{i=1}^n$
 n_{exec} = número de execuções do algoritmo FCM

Output : $\mathbb{C}' = \{C'_j\}_{j=1}^m$

- 1 **foreach** $l \in [1, n_{exec}]$ **do**
- 2 $m \leftarrow \lfloor n/5 \rfloor$
- 3 $\mathbb{C}_l \leftarrow$ FCM aplicado sobre o conjunto \mathbb{F} com m grupos
- 4 **end**
- 5 **foreach** $F_i \in \mathbb{F}$ **do**
- 6 **foreach** $l \in [1, n_{exec}]$ **do**
- 7 $\mathbb{C} \leftarrow \mathbb{C}_l$
- 8 **foreach** $j \in [1, m]$ **do**
- 9 **if** $F_i \in C_j$ **then**
- 10 $C'_j \leftarrow C_j$
- 11 Interrompe *loop*
- 12 **end**
- 13 **end**
- 14 **end**
- 15 $C'_j \leftarrow$ solução da [Equação 4.11](#).
- 16 **end**
- 17 $\mathbb{C}' \leftarrow \mathbb{C}'$ após a eliminação de grupos C'_j idênticos
- 18 $m \leftarrow$ novo número de grupos

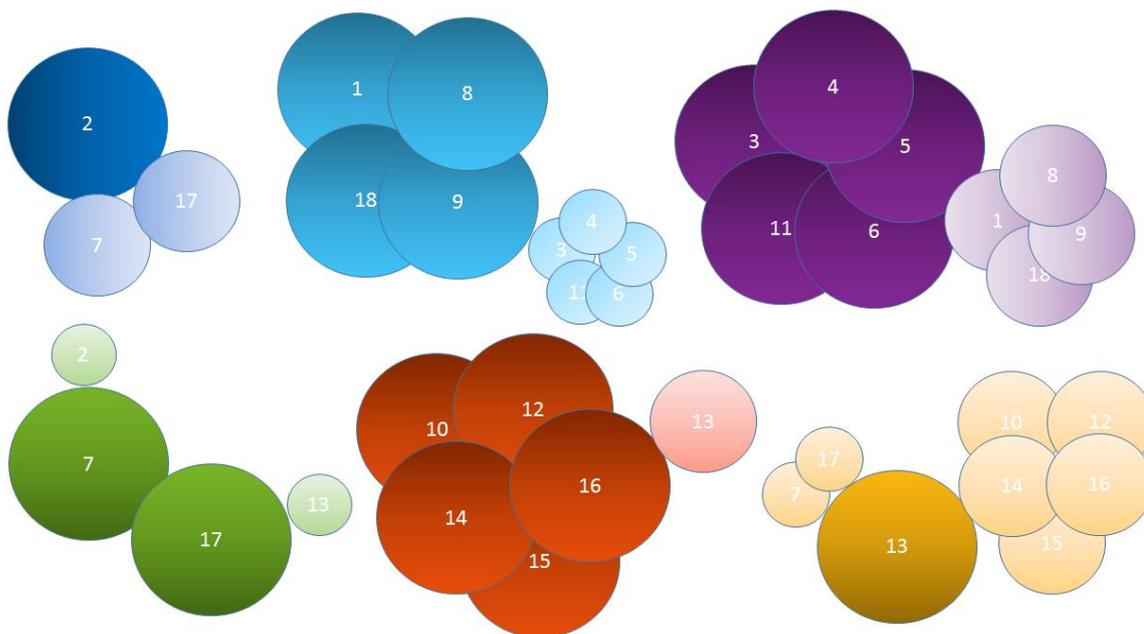
degradação são mostradas pela [Figura 33](#) ⁵.

Na [Figura 32](#), cada círculo equivale a representação de um elemento F_i , sendo i um índice que aponta para um dado reflexo especular sendo agrupado. Os nichos definidos por cada cor equivalem aos novos grupos criados pelo método proposto. Tal grupo é formado apenas pelos círculos de maiores diâmetros em cada nicho, enquanto que os círculos com menores diâmetros mostram a frequência com que outros elementos foram agrupados aos elementos do grupo em questão durante as 30 execuções do FCM. O número inicial de grupos no qual os dados são agrupados é $m = 4$, ou seja, o algoritmo FCM é executado 30 vezes, e em cada execução, os dados são particionados em 4 grupos. O elemento F_{13} (círculo de cor alaranjada/amarelada com índice 13), por exemplo, é agrupado junto aos elementos F_7 e F_{17} em 23,3% das execuções do FCM (7 execuções), enquanto que o mesmo elemento é agrupado junto aos elementos $F_{10}, F_{12}, F_{14}, F_{15}$ e F_{16} em 76,66% das execuções (23 execuções). Logo, na [Figura 32](#), podemos ver que os círculos referentes aos elementos F_7 e F_{17} possuem diâmetros menores pois foram agrupados ao elemento F_{13} em um número menor de execuções do FCM do que os elementos $F_{10}, F_{12}, F_{14}, F_{15}$ que foram agrupados ao elemento F_{13} um número maior de vezes. A intersecção entre todos os 30 grupos resultantes desse processo, é apenas o elemento de índice 13, logo um novo grupo é criado contendo

⁵ As dimensões da PSF foram aumentadas para melhor compreensão. As dimensões reais tanto da imagem, quanto da PSF são: 574×500 e 25×25 , respectivamente.

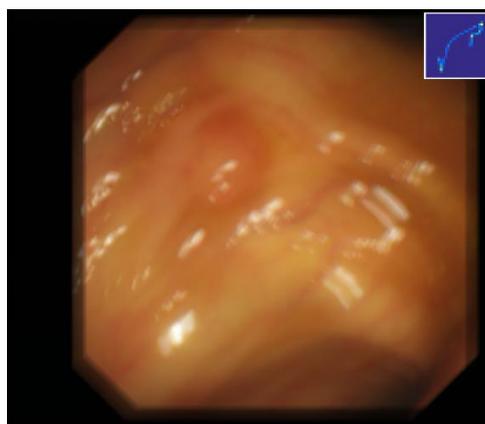
os elementos dessa intersecção, que nesse caso, se resume a um único elemento. Nesse caso podemos observar que os novos grupos ficaram definidos por 6 cores distintas, ou seja, é possível ver que, apesar do número de grupos inicial ter sido $m = 4$, o número de grupos final nesse processo foi $m = 6$.

Figura 32 – Ilustração gráfica do agrupamento proposto sobre uma imagem contendo $n = 18$ reflexos especulares após repetidas execuções do FCM.



Fonte: Elaborada pela autora.

Figura 33 – Imagem degradada e sua PSF de degradação.



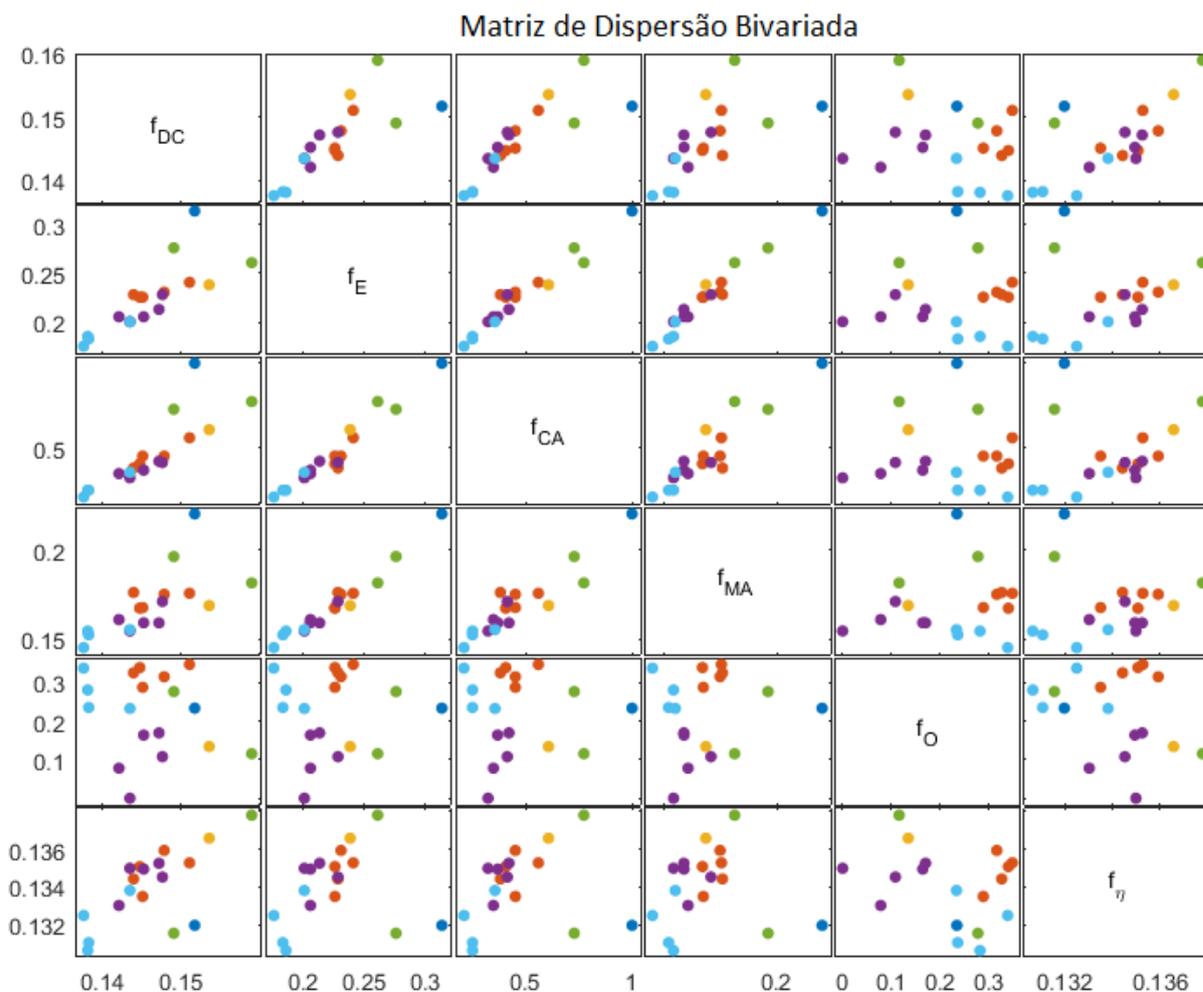
Fonte: Elaborada pela autora.

Por fim, podemos então afirmar que o método de particionamento aqui proposto, com base no algoritmo FCM, analisa a frequência com que os mesmos elemento de \mathbb{F} são classificados como pertencentes a um mesmo grupo. Com base nessa análise de frequência,

um novo particionamento é realizado. Dessa forma, o número final de grupos pode ser maior ou igual ao número inicial m . O termo $E_{C_j}^{R_i}$ refere-se então ao fragmentos de E que contém o reflexo especular E^{R_i} e que foi agrupado no grupo C_j , de acordo com a nossa adaptação do algoritmo FCM.

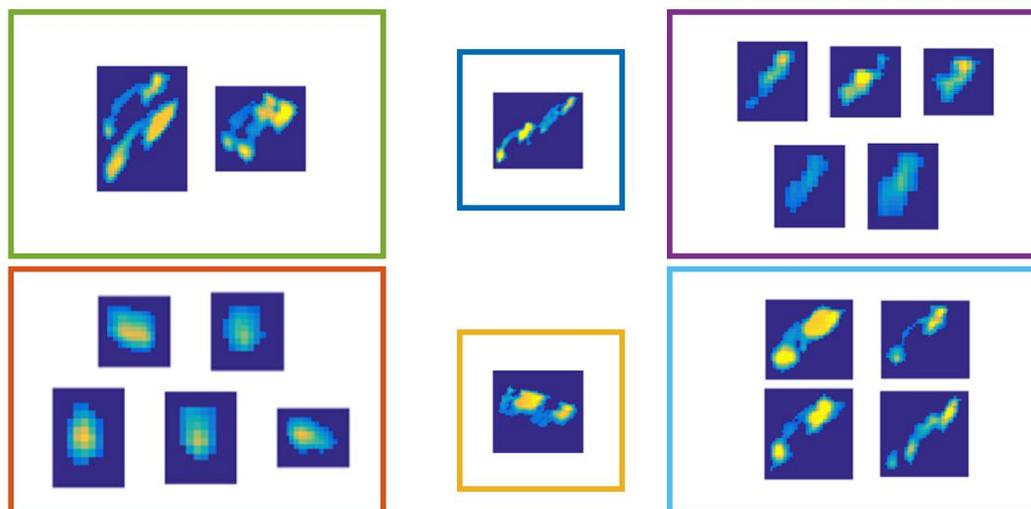
Na Figura 34, podemos observar a matriz contendo os gráfico de dispersão bivariada das seis características extraídas. Diferentes cores associadas aos marcadores representam os diferentes grupos resultantes do processo descrito acima. Para melhor compreensão, as cores seguem o mesmo padrão da Figura 32. Como podemos observar na Figura 35 os reflexos especulares são agrupados de acordo com propriedades de forma, espaciais e de intensidade e os reflexos no grupo delimitado pela cor azul claro são os que melhor representam a PSF real da degradação sofrida por esta imagem (ver Figura 33).

Figura 34 – Gráfico de dispersão bivariada das seis características extraídas de cada elemento i referente a cada reflexo especular na imagem: $F_i = \{f_{DC}, f_E, f_{CA}, f_{MA}, f_O, f_\eta\}$. Cada cor diferente associadas ao marcadores nos gráficos representa diferentes grupos aos quais cada reflexo foi associado.



Fonte: Elaborada pela autora.

Figura 35 – *Highlights* agrupados.



Fonte: Elaborada pela autora.

4.2.3 Fusão de Reflexos Especulares - Geração de PSFs em Potencial

Para cada grupo resultante do processo de agrupamento, os reflexos especulares do conjunto \mathbb{E}^R são então fundidos em um único elemento que chamaremos de **PSF em potencial**. Após encontradas, apenas uma dessas PSFs em potencial é escolhida automaticamente para ser usada posteriormente como ponto de partida no processo de estimação da PSF da degradação.

A motivação para o uso dessas PSFs em potencial resultantes de um processo de fusão de reflexos em detrimento do uso direto de um único reflexo especular para a estimação da PSF da degradação, é que um único reflexo pode estar parcialmente ou completamente saturado, corrompido por ruído ou outra distorção local, contendo então informações limitadas sobre a degradação. Nós partimos da hipótese de que uma PSF em potencial, gerada a partir da fusão de reflexos semelhantes - que compartilham características de forma, espaciais e de intensidade (ver Subseção 4.2.1) - se complementam e portanto, contêm mais informações úteis sobre a degradação real sofrida pela imagem. Em outras palavras, a estimação da degradação a partir destas PSFs em potencial é mais precisa e pode trazer melhores resultados no processo de restauração da imagem do que o uso de reflexos especulares individualmente.

Como já mencionamos, [Mai e Liu \(2015\)](#) propuseram um método de fusão de PSFs para estimação da degradação sofrida por uma imagem. Este método utiliza técnicas de aprendizado supervisionado para combinar PSFs estimadas por diferentes métodos de deconvolução cega. Uma vez que maior parte dos métodos de deconvolução cega para a estimação da PSF trabalha dentro do modelo de estimação MAP (ver Subseção 2.4.2),

os mesmo possuem, no geral, um custo computacional elevado. Sendo assim, a fusão de PSFs estimadas a partir desses métodos é computacionalmente cara. Nossa proposta é que esta fusão seja feita sobre informações retiradas da própria imagem sem envolver outros métodos de estimação de PSFs *a priori*.

O método de fusão que propomos é simples e baseado em uma cálculo de mediana ponderada pelo *coeficiente de correlação de Pearson* entre os reflexos especulares pertencentes a um dado grupo j . Tal método foi desenvolvido para ser rápido em lidar com uma grande quantidade de reflexos a serem fundidos.

Em estatística, o coeficiente de correlação de Pearson $\rho(X, Y)$ é uma medida do grau de relação linear entre duas variáveis aleatórias quantitativas X e Y . Este coeficiente está definido no intervalo $[-1, 1]$, sendo que o valor 0 (zero) indica que não há relação linear entre X e Y , o valor 1 indica uma relação linear perfeita, enquanto o valor -1 refere-se uma relação linear perfeita mas inversa, ou seja, quando uma das variáveis aumenta a outra diminui. Quanto mais próximo estiver de 1 ou -1, mais forte é a relação linear entre X e Y . Este coeficiente, normalmente representado pela letra ρ pode ser calculado como segue:

$$\rho(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X) \cdot var(Y)}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{(x_i - \bar{x})^2} \cdot \sqrt{(y_i - \bar{y})^2}} \quad (4.12)$$

onde $cov(\cdot, \cdot)$ refere-se ao valor de covariância entre duas variáveis aleatórias, enquanto $var(\cdot)$ refere-se ao valor da variância de uma variável aleatória.

A fusão dos reflexos especulares E^{R_i} associados a um grupo $C_j \in \mathbb{C}$ é realizada com base em um cálculo de mediana ponderada. Os pesos utilizados nesse processo são os coeficientes de correlação entre esses reflexos. O método de fusão aqui proposto pode ser descrito pelos seguintes passos:

1. Para cada grupo $C_j \in \mathbb{C}$, os fragmentos $E^{R_i} \in \mathbb{E}^R$ contendo os reflexos especulares associados ao mesmo são redimensionados para as dimensões do maior fragmento encontrado nesse grupo.
2. Para cada E^{R_i} associado a um determinado grupo C_j , um valor de peso w_i é calculado com base no coeficiente de correlação entre o mesmo e os outros reflexos no grupo.
3. Para cada grupo C_j , um cálculo de mediana ponderada com os pesos w_i calculados é realizado, a fim de gerar a PSF em potencial que represente o grupo em questão.

Considerando que cada grupo C_j seja associado a q fragmentos, para cada $E_{C_j}^{R_i}$ $i = \{1, 2, \dots, q\}$, nós calculamos o valor do peso w_i :

$$w_i = \sum_{r=1}^q \rho(E_{C_j}^{R_i}, E_{C_j}^{R_r}), \quad \forall i \neq r \quad (4.13)$$

o valor de r , tal qual o valor de i também indexa os fragmentos associados ao grupo C_j , logo, $r = \{1, 2, \dots, q\}$.

Após calculados os valores de w_i , os mesmos são escalonados para o intervalo $[0, 1]$, em seguida são utilizados no processo de fusão dos reflexos especulares associados ao grupo, baseado no método clássico de cálculo de mediana ponderada (M.A., 1888), gerando assim para cada grupo uma PSF em potencial.

A Figura 39 nos mostra o resultado da fusão dos reflexos especulares agrupados (mostrados pela Figura 35). Observamos que a fusão destes reflexos não fere os pré-requisitos de que a PSF estimada deve ser esparsa, positiva e com um suporte pequeno quando comparada à imagem sendo restaurada. Neste trabalho, as PSFs em potencial geradas nesse processo são definidas pelo conjunto $\mathbb{P} = \{P_j\}_{j=1}^m$, sendo o número delas igual ao número de grupos m .

4.2.4 Encontrando a Melhor PSF em Potencial

Sabemos que a PSF em potencial resultante do processo anterior deve possuir uma trajetória bem definida e ter uma forma parecida com a PSF real da degradação. Infelizmente, uma vez que estamos propondo um método de deconvolução cega, nós não temos acesso a PSF real do sistema. Com base na ideia de que é possível recuperar uma boa aproximação da densidade espectral da PSF da degradação diretamente da imagem borrada (GOLDSTEIN; FATTAL, 2012), nós selecionamos então uma das PSFs em potencial encontradas utilizando a métrica baseada em densidade espectral proposta por Hu et al. (2014) e coeficientes de correlação de Pearson ρ .

Vamos definir aqui o conjunto $\mathbb{B}^{\mathbb{R}} = \{B^{R_i}\}_{i=1}^n$ formado pelos fragmentos da imagem original borrada B que contêm as regiões de reflexo especular definida por \mathbb{R} . Utilizando a métrica proposta por Hu et al. (2014), apresentada na Equação 2.16, procuramos por um **reflexo especular de referência** $B^{R_{ref}} \in \mathbb{B}^{\mathbb{R}}$ tal que:

$$B^{R_{ref}} = \arg \min_{B^{R_i}} d(B^{R_i}, B) \quad (4.14)$$

De posse de $B^{R_{ref}}$, encontramos seu equivalente $E^{R_{ref}} \in \mathbb{E}^{\mathbb{R}}$ que, por sua vez, representa o fragmento contendo a mesma região R_i do reflexo $B^{R_{ref}}$, porém sendo na componente especular E . Finalmente, para cada PSF em potencial do conjunto \mathbb{P} , nós calculamos os coeficientes de correlação $\rho_j = \rho(P_j, B^{R_{ref}})$. A melhor PSF em potencial P_{ref} será aquela que minimiza o valor de ρ_j .

$$P_{ref} = \arg \min_{P_j} \rho(P_j, E^{R_{ref}}) \quad (4.15)$$

A Figura 39 mostra a melhor PSF em potencial P_{ref} escolhida para o caso da imagem mostrada na Figura 33. É possível observar que esta PSF, marcada em azul claro, possui maior similaridade com a PSF real do sistema que as outras cinco PSFs em potencial e esta será então utilizada como ponto de partida no processo da estimação da degradação. As cores atribuídas a cada PSF em potencial mostrada nessa figura remete as cores atribuídas aos grupos de *highlights* mostradas na Figura 32.

4.2.5 Estimação da PSF da Degradação e Restauração da Imagem

Recentemente, muitos progressos tem sido feitos em métodos de estimação da PSF de degradações complexas (XU; JIA, 2010; KRISHNAN; TAY; FERGUS, 2011; PAN et al., 2016). O sucesso desses métodos se deve, em parte, à implementação de uma **abordagem multi-escala** no processo de estimação. No geral, nos métodos de restauração presentes no estado da arte, o processo de estimação da PSF é realizado dentro de uma perspectiva *coarse-to-fine*, ou seja, usando imagens em multi-escala obtidas pela uso de pirâmide gaussiana.

Nesse tipo de abordagem, em cada nível da pirâmide, a estimação de k é realizada utilizando também *priors* para a imagem nítida no domínio do gradiente ∇I (ver Subseção 2.4.2) sendo a imagem I estimada, chamada muitas vezes de **imagem nítida intermediária**. Como já mencionamos na Seção 2.5, muitos métodos regularizam ainda mais o problema de otimização utilizando recursos como ênfase em arestas (*Edge Emphasizing Operations*) para restaurar imagens naturais (XU; JIA, 2010), ou uso de canais escuros (*dark channels*) (PAN et al., 2016) da imagem, para tornar o método de restauração mais genérico, sendo aplicável também em imagens de faces, texto e imagens naturais com baixa iluminação. Sendo assim, o problema definido pela Equação 2.12, adicionando-se uma distribuição não-uniforme para k e outros possíveis termos de regularização adicionais, pode ser escrito como:

$$\arg \min_{I,k} \|B - I * k\|_p^2 + \gamma \|k\|_p^2 + \mu \|\nabla I\|_p + \psi(I) \quad (4.16)$$

onde o primeiro termo define que o resultado da convolução entre a imagem intermediária estimada I e a PSF da degradação k seja similar à imagem observada B ; o segundo termo refere-se a uma regularização sobre PSF k ; o terceiro termo trata-se de uma regularização definida no domínio do gradiente da imagem I ; o quarto termo $\psi(I)$ equivale a possíveis termos de regularização adicionais sobre I , como por exemplo, o uso de canais escuros; p se refere a norma- l_p adotada e, γ e μ são parâmetros de peso. No geral, nós usamos métodos de descida (*coordinate descent*) para solução computacional do problema de otimização de

maneira alternada, para I :

$$\arg \min_{I,k} \|B - I * k\|_p^2 + \mu \|\nabla I\|_p + \psi(I) \quad (4.17)$$

e para k :

$$\arg \min_{I,k} \|B - I * k\|_p^2 + \gamma \|k\|_p^2 \quad (4.18)$$

De maneira superficial, na abordagem $\text{MAP}_{I,k}$, para cada nível da pirâmide, o problema de otimização clássico a se resolver no processo de estimação da PSF k fica definido pelo Algoritmo 3.

Algoritmo 3: Método clássico de estimação da PSF de degradação de uma imagem

Input : Imagem borrada de entrada B

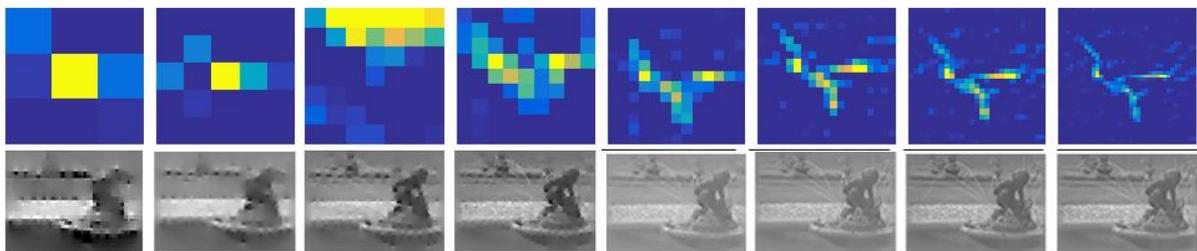
Output : PSF estimada \hat{k}

Imagem nítida intermediária \hat{I}

- 1 $\hat{k} \leftarrow$ Resultados do nível anterior da pirâmide
 - 2 **while** $i \leq \text{max_iter}$ **do**
 - 3 $\hat{I} \leftarrow$ Estimação de I pela [Equação 4.17](#).
 - 4 $\hat{k} \leftarrow$ Estimação de k pela [Equação 4.18](#).
 - 5 **end**
-

A [Figura 36](#) mostra um exemplo de uma sequência de PSFs estimadas dentro dessa abordagem multi-escala e o fluxograma mostrado na [Figura 37](#) ilustra como se dá, no geral, todo o processo de restauração de uma imagem utilizando essa abordagem.

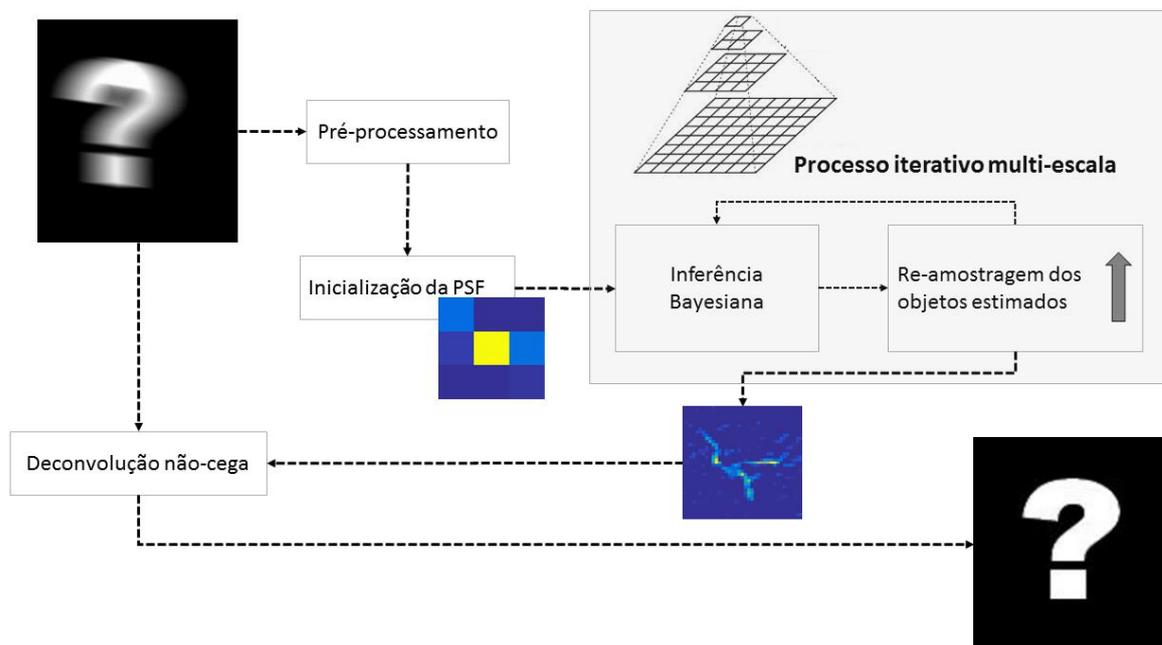
Figura 36 – Sequência de PSFs estimadas dentro dessa abordagem multi-escala.



Fonte: Adaptado de [Fergus et al. \(2006\)](#)

Diferentemente da maioria dos métodos propostos, nós partimos da premissa de que, uma vez que utilizamos informações sobre reflexos especulares no processo de estimação da PSF em potencial escolhida, e uma vez que esta já possui semelhanças significativas à PSF real do sistema, podemos dispensar a estimação de k utilizando a abordagem multi-escala ([HUA; LOW, 2011](#); [HU et al., 2014](#); [XUELING; YANNING, 2014](#)). Dessa

Figura 37 – Método comum de restauração usando a abordagem multi-escala.



Fonte: Elaborada pela autora.

forma, a estimação de k é realizada dentro do contexto $\text{MAP}_{I,k}$, porém sem o uso de pirâmide gaussiana para realizar reduções na imagem.

Para estimar a PSF k , uma adaptação do método de Pan et al. (2016) foi utilizada. Este método, estima a PSF usando regularização baseada na norma l_0 e canais escuros. Em experimentos, percebemos que no contexto de imagens de endoscopia óptica, não foi necessário fazer uso de canais escuros para auxiliar na estimativa de k , e isso se dá basicamente por dois motivos: (1) o uso de canais escuros foi proposto *a priori* para regularizar ainda mais o problema de otimização na intenção de evitar o efeito delta (ver Subseção 2.4.2.3), porém uma vez que partimos de uma PSF em potencial que já possui semelhanças com a PSF real do sistema, é pouco provável termos uma imagem restaurada semelhante à imagem borrada; (2) imagens de endoscopia óptica são homogêneas (fundo parcialmente homogêneo), com poucas áreas de arestas bem definidas, logo a escassez dessas regiões torna o uso de canais escuros pouco útil no processo de estimação de k . Sendo assim, para a estimação da degradação desse tipo específico de imagens, não se fez necessária a adição de mais termos de regularização à solução do problema. A vantagem nesse método adaptado é uma PSF estimada de forma precisa e próxima à PSF real da degradação, porém com uma redução significativa no custo computacional associado ao processo. A Figura 38 ilustra a diferença do método de restauração proposto ao método tradicional mostrado na Figura 37. Segundo a adaptação do método de estimação de Pan et al. (2016), no nosso problema de otimização, alternamos na solução da imagem nítida

intermediária I :

$$\arg \min_I \|I * k - B\|_2^2 + \mu \|\nabla I\|_0 \quad (4.19)$$

e em k :

$$\arg \min_k \|I * k - B\|_2^2 + \lambda \|k\|_2^2 \quad (4.20)$$

O uso da norma l_0 no segundo termo da [Equação 4.19](#), foi usada em detrimento da norma l_1 , mais comumente utilizada. O uso desta regularização foi feita com base no trabalho de [Xu, Zheng e Jia \(2013\)](#), no qual os autores mostram que, uma vez que o uso de l_0 está diretamente associada a esparsidade da imagem, pois esta nos dá a quantidade de elementos diferentes de zero na imagem, o seu uso garante que apenas a mudança saliente na imagem sejam preservadas e usadas, tornando a solução do problema mais rápida do que outras alternativas mais implícitas para a regularização da esparsidade de ∇I .

Dessa forma, o método de estimação clássica, mostrado pelo [Algoritmo 3](#) adaptado para nossas necessidades, fica enfim reescrito como segue no [Algoritmo 4](#).

Algoritmo 4: Método proposto de estimação da PSF de degradação

Input : Imagem borrada de entrada B
 Melhor PSF em potencial escolhida P

Output : PSF estimada \hat{k}
 Imagem nítida intermediária \hat{I}

```

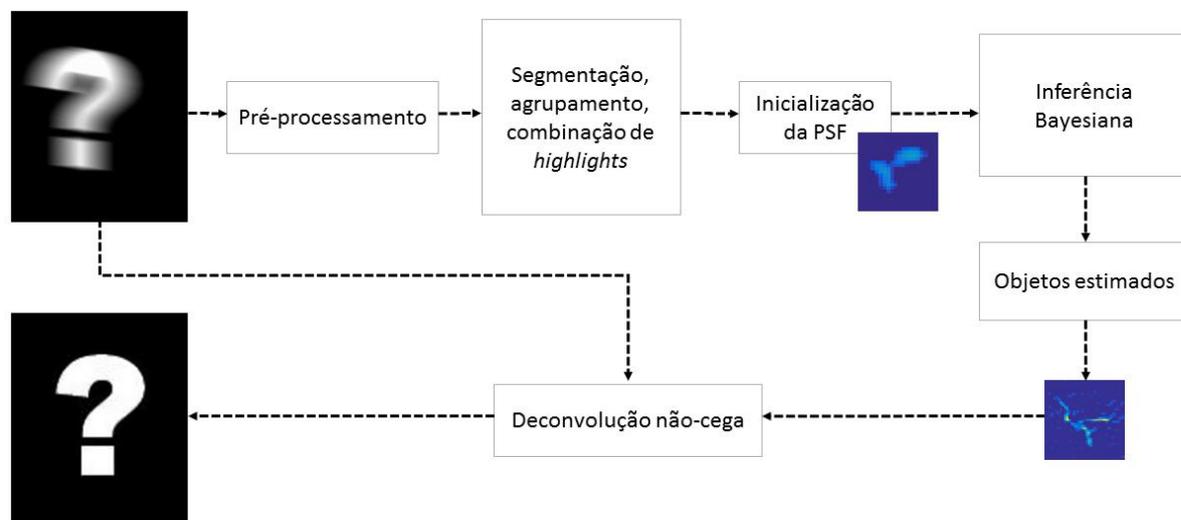
1  $\hat{k} \leftarrow P$ ;
2 while  $i \leq \text{max\_iter}$  do
3    $\hat{I} \leftarrow$  Estimação de  $I$  pela Equação 4.19.
4    $\hat{k} \leftarrow$  Estimação de  $k$  pela Equação 4.20.
5 end
```

Na [Figura 39](#) mostramos um exemplo com a PSF real do sistema, marcada mais à esquerda em preto, as PSFs em potencial resultantes do processo de agrupamento e fusão de reflexos especulares, marcadas em cinza (ver [Subseção 4.2.2](#) e [Subseção 4.2.3](#)), a melhor PSF em potencial escolhida, marcada em azul claro mais à direita, (ver [Subseção 4.2.4](#)), e por fim, a PSF k , estimada a partir da PSF em potencial escolhida, utilizando o [Algoritmo 4](#).

4.2.5.1 Restauração da Imagem

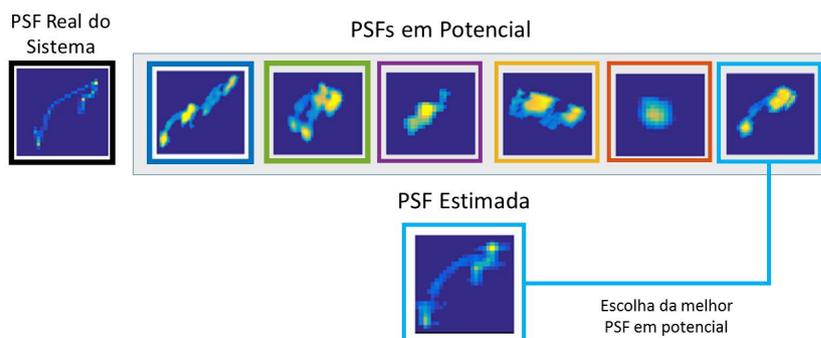
Uma vez que o foco do trabalho apresentado nesta tese é estimar a PSF k do sistema através do uso de reflexos especulares, nós utilizamos um método de deconvolução não cega presente no estado da arte e proposto por [Xu e Jia \(2010\)](#) para restaurar a

Figura 38 – Método de restauração proposto.



Fonte: Elaborada pela autora.

Figura 39 – Fusão de reflexos especulares para geração de PSFs em potencial e estimação da PSF da degradação. De cima para baixo: PSF real da degradação; PSFs em potencial geradas pelo processo de fusão (ver Subseção 4.2.3), aquela marcada em azul claro equivale a melhor PSF em potencial selecionada automaticamente (ver Subseção 4.2.4); PSF estimada a partir da melhor PSF em potencial.



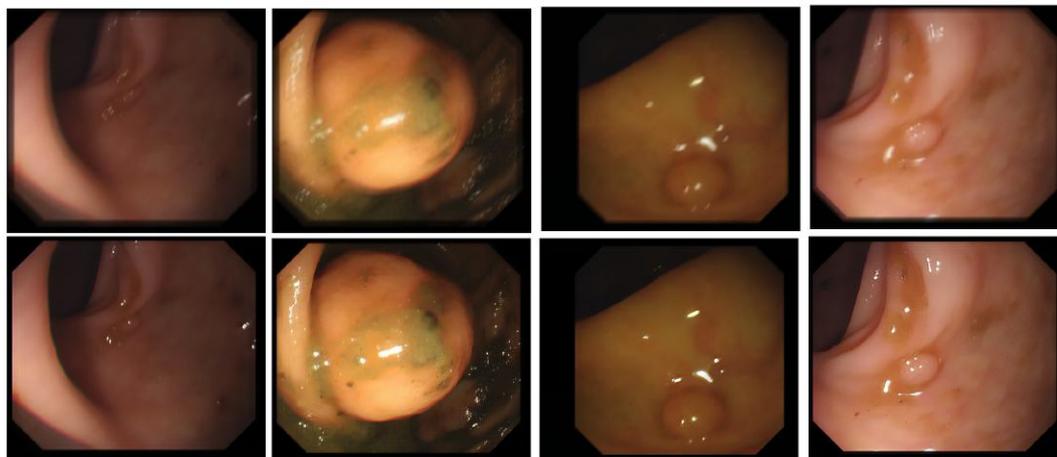
Fonte: Elaborada pela autora.

imagem de endoscopia óptica, após a estimação da PSF segundo o método já descrito. Esse método de estimação contém penalidades não-lineares usando a norma l_1 para os termos de ajuste de dados e de regularização do problema.

A Figura 40 ilustra alguns resultados do processo de restauração de imagens proposto neste capítulo. Mais resultados são mostrados no Capítulo 5. Nos experimentos que validam o método aqui proposto em comparação com alguns outros métodos do estado da arte, apresentamos também custos computacionais e valores de parâmetros usados no

processo de estimação de k e I .

Figura 40 – Resultados do processo de restauração de imagens endoscópicas com base no agrupamento e fusão de reflexos especulares. De cima para baixo: Imagem degradada por borramento e imagem restaurada.



Fonte: Elaborada pela autora.

5 EXPERIMENTOS E RESULTADOS

Neste capítulo apresentamos a validação tanto do método de segmentação de reflexos especulares apresentados no [Capítulo 3](#) quanto do método de restauração de imagens apresentado no [Capítulo 4](#), bem como apresentamos todos os valores de parâmetros utilizados e números relativos aos tempos de processamento de ambos os processos. Os resultados obtidos em ambos os métodos propostos foram comparados com outros resultados do estado da arte utilizando uma base de dados pública de imagens de endoscopia óptica.

5.1 Base de Imagens Utilizada nos Experimentos

Para realizar nossos experimentos, usamos a base de imagens *CVC-ColonDB* ([BERNAL; SÁNCHEZ; VILARINO, 2012](#)). Esta base é disponibilizada publicamente ¹ para fins de pesquisa e desenvolvimento de soluções computacionais que assistam procedimentos de colonoscopia óptica.

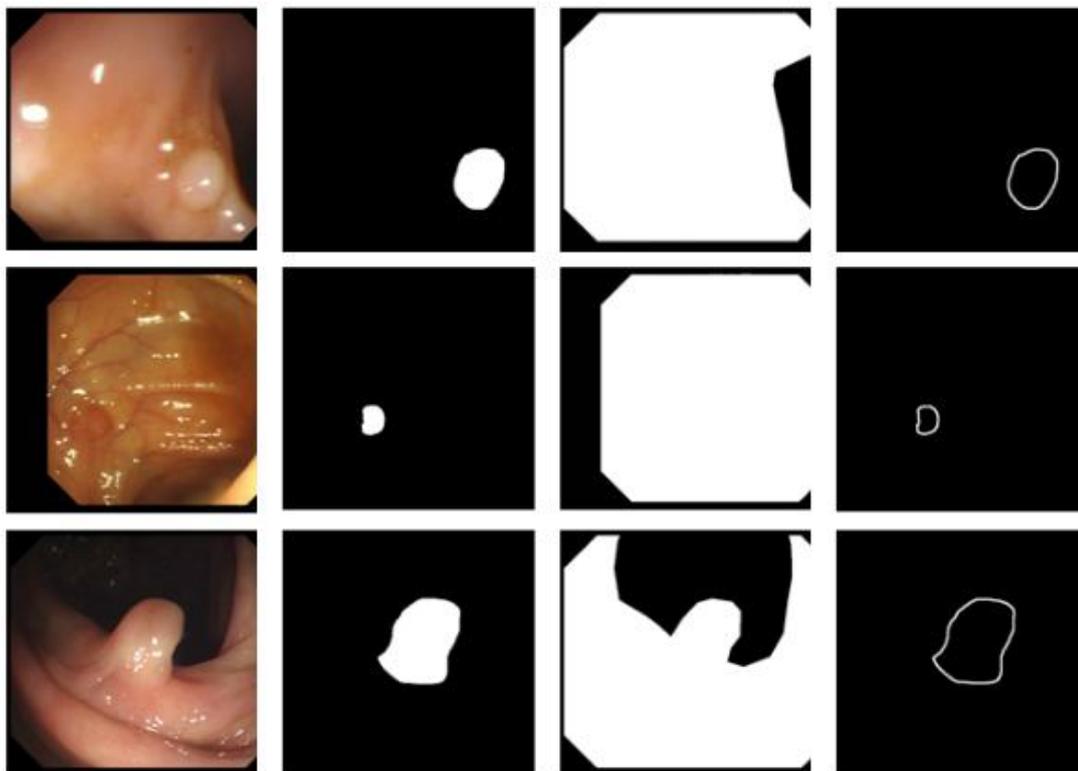
A divulgação da base busca estimular pesquisas no auxílio à detecção automática de câncer de cólon em vídeos de colonoscopia de alta definição por meios de técnicas robustas de Visão Computacional. O objetivo é estimular métodos de detecção eficazes e que funcionem em tempo real. Sendo assim, todas as imagens da base apresentam pólipos (ver [Seção 5.4](#)) em sua composição. Como mostra [Figura 41](#), a base consiste de 1200 imagens, todas no formato *bmp*, divididas em 4 grupos: (1) Imagens coloridas originais; (2) Máscaras binárias indicando regiões de pólipo; (3) Máscaras binárias indicando regiões chamadas de *não-informativas* e (4) máscaras binárias com informações sobre os contornos de pólipos. Sendo assim, para nossos propósitos, nós utilizamos apenas as imagens coloridas originais, que se resumem a 300 imagens no total.

5.2 Validação do Método de Segmentação de Reflexos Especulares

A validação do método de segmentação proposto no [Capítulo 3](#) foi realizado em 100 imagens extraídas da base de imagens através de um processo de amostragem aleatória simples. As componentes especulares E resultante do processo de segmentação aqui proposto foram comparadas com alguns resultados do estado da arte: [Arnold et al. \(2010\)](#), [Meslouhi et al. \(2011\)](#) e [Chwyl et al. \(2015\)](#). Foram escolhidos tanto trabalhos recentes, como trabalhos com maiores números de citações para serem comparados ao método aqui proposto.

¹ <http://mv.cvc.uab.es/projects/colon-qa>

Figura 41 – Exemplos de Imagens da Base *CVC-ColonDB*. Da esquerda para a direita: Imagens coloridas originais; Máscaras binárias indicando regiões de pólipo; Máscaras binárias indicando regiões chamadas de *não-informativas* e máscaras binárias com informações sobre os contornos de pólipos.

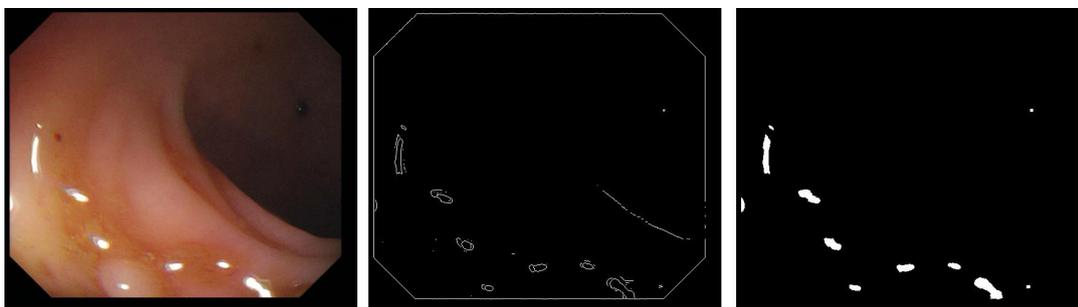


Fonte: [Bernal, Sánchez e Vilarino \(2012\)](#).

Infelizmente, a base *CVC-ColonDB* não possui máscaras binárias com rótulos associados à localização de regiões de reflexos especulares. Para os propósitos deste trabalho, essas máscaras foram então criadas através de um processo semi-automático de rotulação. Inicialmente, uma detecção mais grosseira dessas regiões foi feita na imagem utilizando-se um filtro de detecção de arestas baseado no operador derivativo Sobel. Em seguida, cada máscara resultante desse processo foi editada manualmente de maneira que estas contivesse apenas informações sobre as regiões de reflexos especulares. A [Figura 42](#) ilustra como se deu esse processo. Essas máscaras binárias são então utilizadas como *ground truth* para a comparação do nosso resultado com os resultados do estado da arte.

Por se tratarem de métodos de segmentação grosseira (ver Seção 2.2), os métodos de [Arnold et al. \(2010\)](#) e [Meslouhi et al. \(2011\)](#) produzem máscaras binárias como resultado da detecção de reflexos especulares. O método que propomos neste trabalho produz uma segmentação precisa destes reflexos, ou seja, a componente especular E refere-se a uma máscara em tons de cinza em detrimento de uma máscara binária. Para comparar os resultados do nosso método de segmentação com os resultados de [Arnold et al. \(2010\)](#) e [Meslouhi et al. \(2011\)](#), a componente E foi então convertida em uma máscara binária

Figura 42 – Rotulação de reflexos especulares para a geração do *ground truth*. Da esquerda para a direita: Imagem colorida Original; Detecção de arestas (Operador Sobel) e máscara binária final contendo as regiões de reflexos.

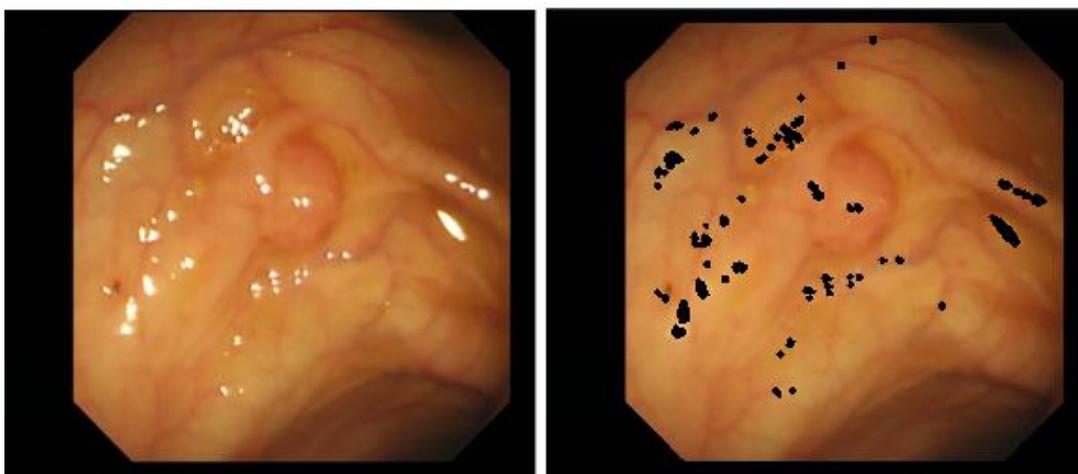


Fonte: Elaborada pela autora.

via uma simples operação de identificação de componentes conexos, considerando uma vizinhança com conectividade de 8 vizinhos.

Uma vez que a componente especular detectada pelo método de Chwyl et al. (2015) trata-se de uma imagem em escala de cinza, tal qual nossa componente E , a comparação no nosso método com os resultados de Chwyl et al. (2015) foi realizada utilizando-se as componentes difusas de ambos os métodos, que referem-se a imagem original colorida sem a componente especular². Como mostra a Figura 43, a componente difusa utilizada como *ground truth* nesse processo de comparação foi obtida extraindo-se as máscaras binárias mostradas na Figura 42 da imagem colorida original.

Figura 43 – Da esquerda para a direita: Imagem original colorida e sua componente difusa.



Fonte: Elaborada pela autora.

² No nosso caso, a componente difusa trata-se da componente A apresentada na Seção 3.3.

5.2.1 Parâmetros Utilizados

No método proposto os parâmetros setados no processo de segmentação foram os valores de relaxamento $\mu = 0.003$ e de peso $\lambda = 0.03$ da [Equação 3.3](#). Esses valores foram utilizados em todas as imagens do experimento.

5.2.2 Métricas do Experimento e Estatísticas

Para as 100 utilizadas, as máscaras binárias resultantes do método de segmentação aqui proposto foram comparadas com as máscaras binárias resultantes dos métodos de segmentação propostos por [Arnold et al. \(2010\)](#) e [Meslouhi et al. \(2011\)](#). A comparação entre os métodos foi alcançada através do uso do **coeficiente de similaridade de Jaccard** (*Jaccard similarity coefficient*). O coeficiente de *Jaccard* mede a similaridade entre duas amostras binárias finitas X e Y , e é definido como o tamanho da intersecção dividido pelo tamanho da união das amostras:

$$J(X, Y) = \frac{X \cap Y}{X \cup Y} \quad (5.1)$$

o valor do coeficiente $J(X, Y)$ é um número real definido no intervalo $[0, 1]$, sendo que o valor 1 indica que X e Y são completamente iguais.

As diferenças entre os métodos de detecção dos reflexos especulares são então avaliadas através de uma análise das 3 amostras de 100 elementos cada, que contêm os valores dos coeficientes de *Jaccard* calculados: A primeira amostra contém valores oriundos da comparação do método proposto de segmentação dos reflexos com relação com o *ground truth*, e a segunda e terceira amostras são oriundas da comparação dos métodos de [Arnold et al. \(2010\)](#) e [Meslouhi et al. \(2011\)](#) com relação ao mesmo *ground truth*.

Fizemos uma análise de variância para avaliar a similaridades entre as 3 amostras contendo os coeficientes de *Jaccard*. Foram encontradas diferenças estatísticas significativas entre as 3 amostras analisadas. Após realizarmos um teste de normalidade *Shapiro-Wilk* ([SHAPIRO; WILK, 1965](#)) sobre estas amostras com grau de confiança $1 - \alpha = 0,95^3$, observamos que no geral, como os valores do *p-value* resultantes dos testes foram menores que α (ver [Tabela 1](#)), rejeitou-se a hipótese de que a distribuição das amostras podem ser aproximadas por uma distribuição normal.

Sendo assim, considerando a não-normalidade das amostras e considerando-se que as mesmas são pareadas (pois os métodos que estão sendo comparados são aplicados sobre a mesma sequência de 100 imagens), a análise de variância do resultado foi realizada através do teste não-paramétrico de *Friedman* ([FRIEDMAN, 1940](#)) e os resultados do ranque do teste são exibidos pelo pós teste de *Nemenyi* ([NEMENYI, 1963](#)). O teste de

³ Os testes de normalidade são utilizados para verificar se a distribuição de probabilidade associada a uma determinada amostra pode ser aproximada pela distribuição normal.

Tabela 1 – Teste de normalidade sobre as amostras contendo os coeficientes de *Jaccard*.

Método	<i>p-value</i>
Arnold et al. (2010)	0,00128
Meslouhi et al. (2011)	0,00048
Método Proposto	0,00243

Fonte: Elaborada pela autora.

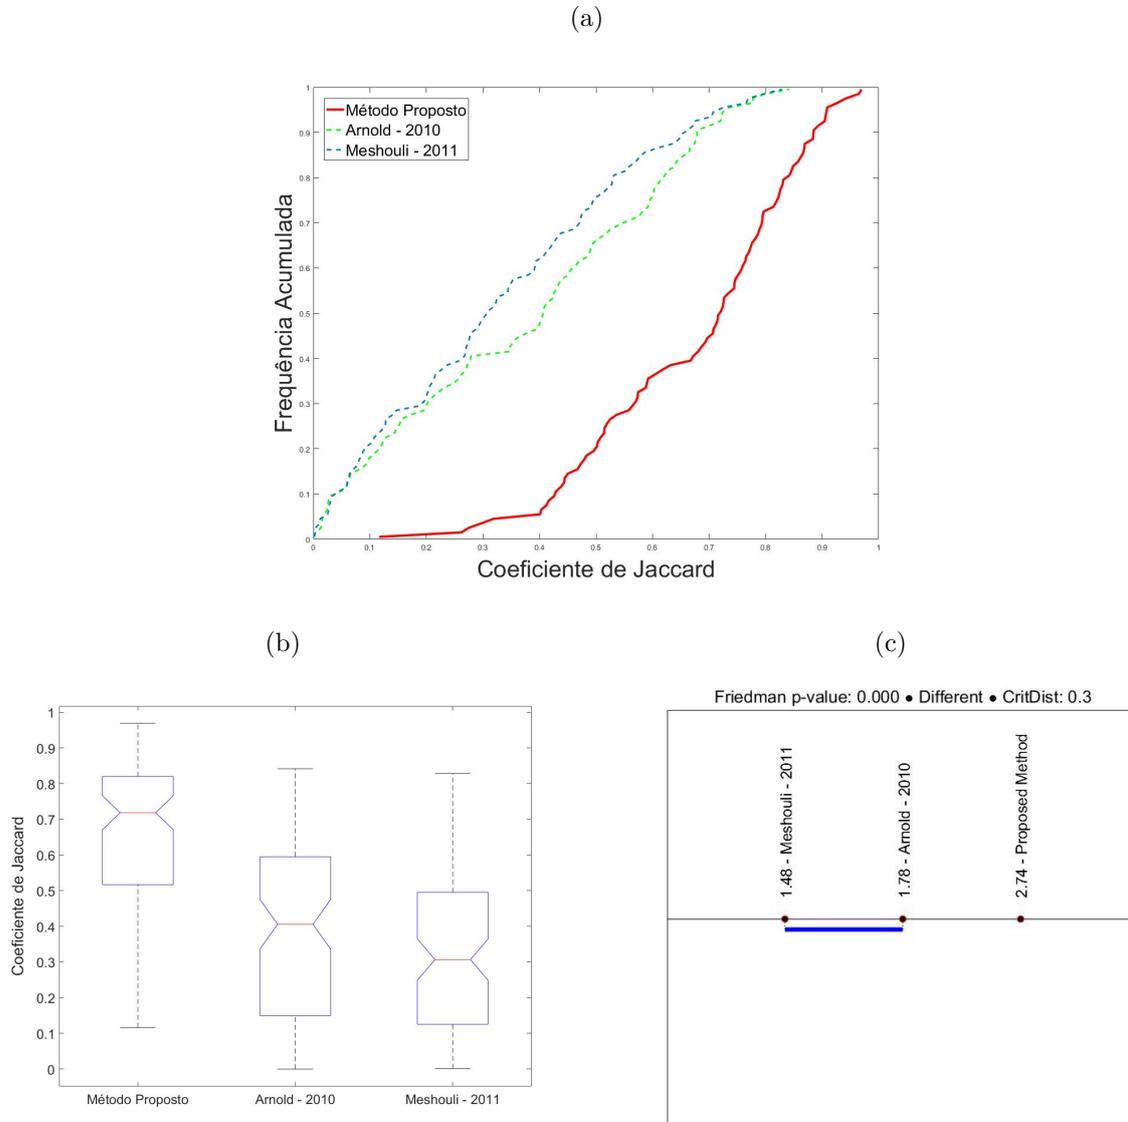
Friedman é o teste não-paramétrico utilizado na comparação de três ou mais amostras pareadas. Ele nos indica se duas ou mais amostras provém de uma mesma população ou se de populações diferentes.

A [Figura 44a](#) mostra o gráfico de frequência acumulada de cada uma das amostras contendo os coeficientes de *Jaccard*. A amostra cuja a curva posiciona-se mais à direita apresenta melhores resultados, uma vez que apresenta valores mais altos para o coeficiente de *Jaccard*. A [Figura 44b](#) mostra *boxplots* para a distribuição das 3 amostras. Uma avaliação visual qualitativa nessa figura nos indica que o método proposto apresenta valores mais altos para o coeficiente, seguido do método proposto por ([ARNOLD et al., 2010](#)) e ([MESLOUHI et al., 2011](#)), respectivamente. O teste de *Friedman* detecta diferenças significantes entre as amostras ($p\text{-value} < 10^{-7}$) que é mostrado através do pós teste de *Nemenyi* na [Figura 44c](#). O método melhor ranqueado corresponde aquele representado mais à direita sobre a linha horizontal. A linha em azul indica que o teste não apontou nenhuma diferença estatística significativa entre os métodos de ([ARNOLD et al., 2010](#)) e ([MESLOUHI et al., 2011](#))(sua distância é menor ou igual a distância crítica 0.3).

Em síntese, nós podemos então concluir que a segmentação resultante do método proposto supera os métodos ([ARNOLD et al., 2010](#)) e ([MESLOUHI et al., 2011](#)). A [Figura 45](#) mostra a diferença entre os resultados dos métodos de segmentação comparados sobre algumas imagens.

Para comparar os resultados do método proposto com os resultados de [Chwyl et al. \(2015\)](#), nós utilizamos uma abordagem diferente. Tal qual o resultado do método proposto, o resultado da componente especular das imagens de endoscopia óptica apresentado por [Chwyl et al. \(2015\)](#) trata-se de uma imagem em tons de cinza ao invés de uma imagem binária (ver [Figura 46](#)). Sendo assim, uma vez que não temos um *ground truth* para realizar comparações com essas imagens em tons de cinza, nós optamos por comparar o resultado das componentes difusas de ambos os métodos sem os reflexos especulares com a imagem RGB original também sem os reflexos especulares.

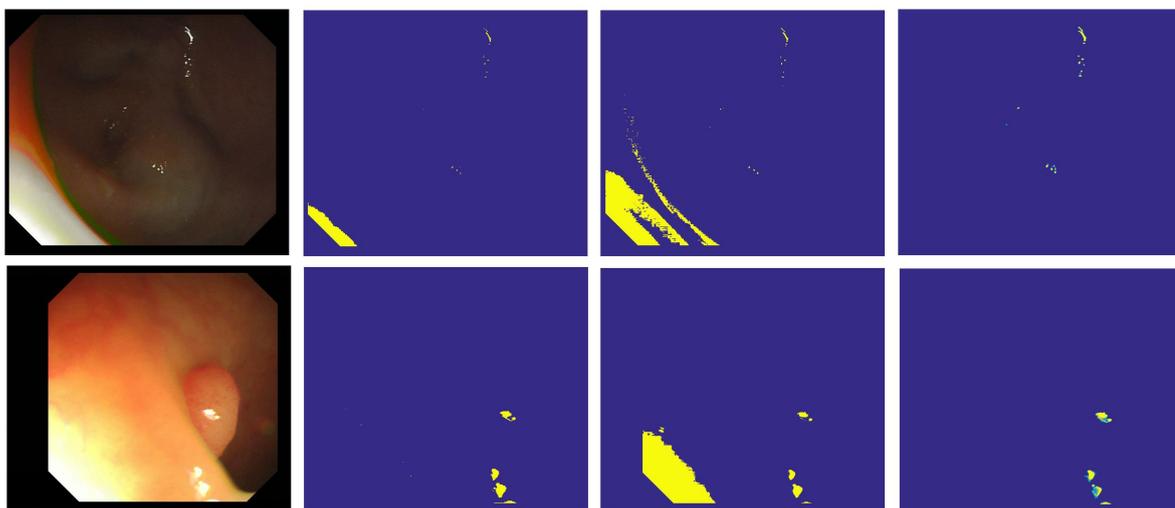
Figura 44 – Análise de variância para avaliar a similaridades entre as amostras contendo os coeficientes de *Jaccard*. (a) Gráfico de frequência acumulada de cada uma das amostras; (b) *boxplots* para a distribuição das amostras; (c) Diferenças significantes entre as amostras pelo teste de *Friedman* e pós teste de *Nemenyi*.



Fonte: Elaborada pela autora.

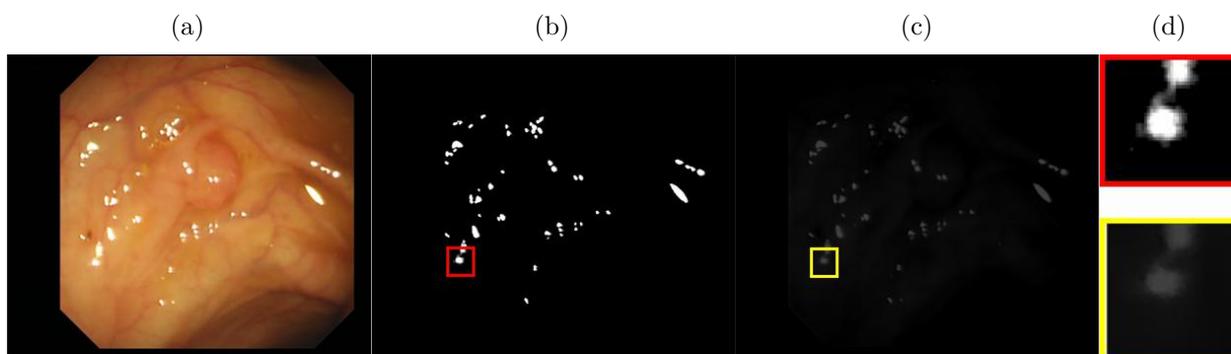
Em todas as imagens comparadas, as regiões dos reflexos especulares foram removidas utilizando-se as marcações manuais já apresentadas (ver Figura 42). Na Figura 47 nós apresentamos as imagens comparadas nesse processo. Na Figura 47a temos a imagem original, na Figura 47b temos a componente difusa A resultante do método proposto e na Figura 47c temos a componente difusa resultante do algoritmo de Chwyl et al. (2015). A ideia por trás dessa comparação é que o método de remoção de reflexos especulares que apresente uma boa performance deve remover tais reflexos, sem remover, entretanto, informações das outras regiões da imagem, pois uma vez que informações como vasos,

Figura 45 – Resultados comparativos do método de segmentação. Da esquerda para a direita: Imagem original; resultado da segmentação de reflexos especulares utilizando o método de [Arnold et al. \(2010\)](#); resultado da segmentação de reflexos especulares utilizando o método de [Meslouhi et al. \(2011\)](#); resultado da segmentação de reflexos especulares utilizando o método aqui proposto.



Fonte: Elaborada pela autora.

Figura 46 – Resultados comparativos do método de segmentação: (a) Imagem Original; (b) Máscara em tons de cinza referente ao componente Especular da Imagem original extraída pelo método proposto; (c) Máscara em tons de cinza referente ao componente Especular da Imagem original extraída pelo método proposto por [Chwyl et al. \(2015\)](#); (d) zoom sobre os componentes especulares.

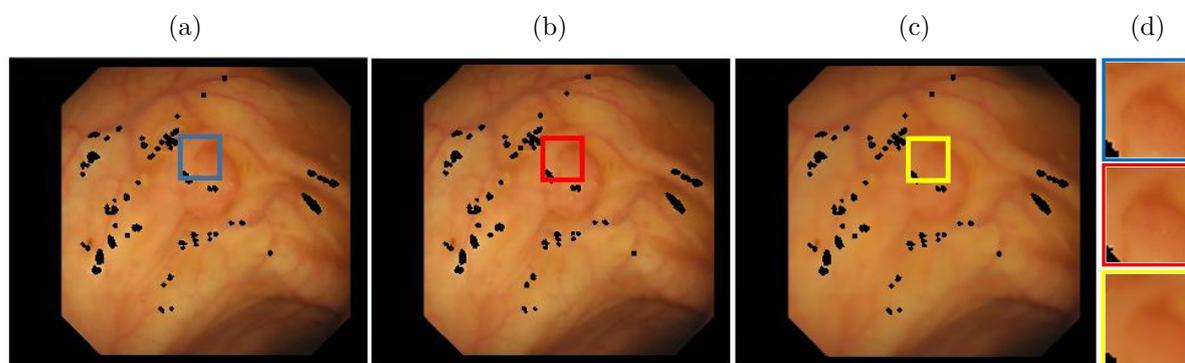


Fonte: Elaborada pela autora.

pólipos, etc, são removidos de maneira equivocada, futuros processos de análise sobre essas imagens - tais como identificação de pólipos, dentre outros males - podem ser prejudicados. Desejamos portanto que as componentes difusas resultantes da separação dos reflexos das imagens originais sejam o mais próximas o possível da imagem original sem os reflexos especulares.

Para realizar a comparação entre as 100 componentes difusas resultantes do método

Figura 47 – (a) Imagem Original sem os reflexos especulares; (b) Componente difusa resultante do método proposto sem os reflexos especulares; (c) Componente difusa resultante método proposto por Chwyl et al. (2015) sem os reflexos especulares; (d) Zoom sobre as componentes difusas.



Fonte: Elaborada pela autora.

proposto e do método de Chwyl et al. (2015), nós utilizamos a métrica de semelhança estrutural SSIM (*Structural SIMilarity* - SSIM) proposta por Wang et al. (2004) para comparar a qualidade dos nossos resultados com os resultados de Chwyl et al. (2015). O coeficiente SSIM é um método completamente referenciado para medir a semelhança entre duas imagens e pode ser visto como uma medida da qualidade entre as imagens sendo comparadas, desde que uma destas imagens seja considerada com qualidade perfeita. Os valores da métrica podem variar de 0 a 1, sendo o valor 1 resultante da comparação de duas imagens iguais. Tal qual no experimento anterior, a amostra cuja a curva posiciona-se mais à direita apresenta melhores resultados. A Figura 48b mostra *boxplots* para a distribuição das 2 amostras. Uma avaliação visual qualitativa nessa figura nos indica que o método proposto apresenta valores mais altos para o coeficiente SSIM. O teste de *Friedman* detecta diferenças significantes entre as amostras ($p\text{-value} < 10^{-6}$) que é mostrado através do pós teste de *Nemenyi* na Figura 48c. O método proposto aparece melhor ranqueado de acordo com o teste.

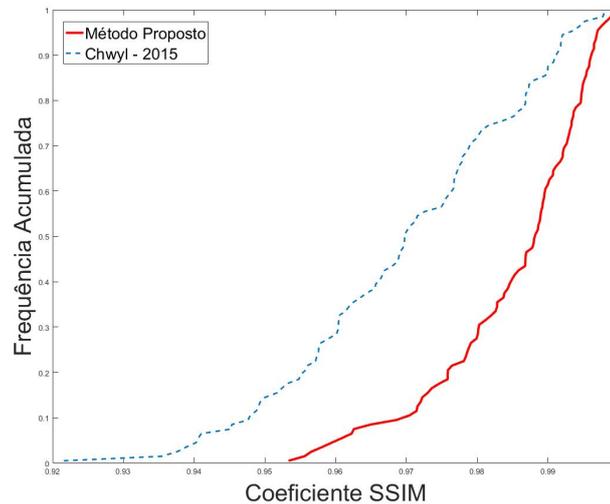
A Figura 49 mostra a diferença entre nosso método de segmentação e o método proposto por Chwyl et al. (2015). A componente especular resultante do método de Chwyl et al. (2015) possui mais informações além dos reflexos especulares encontrados na imagem e, uma vez que estas informações são removidas da componente difusa, a mesma apresenta uma aparência mais suave, perdendo então detalhes importantes sobre pólipos, vasos, etc.

5.2.3 Tempos de Processamento

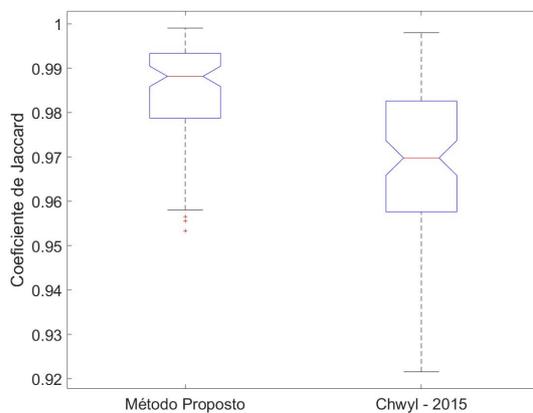
A Tabela 2 apresenta uma lista com os tempos de processamento médios de execução dos métodos de segmentação aqui comparados.

Figura 48 – Análise de variância para avaliar a similaridades entre as amostras contendo os valores para o index SSIM. (a) Gráfico de frequência acumulada de cada uma das amostras; (b) *boxplots* para a distribuição das amostras; (c) Diferenças significantes entre as amostras pelo teste de *Friedman* e pós teste de *Nemenyi*.

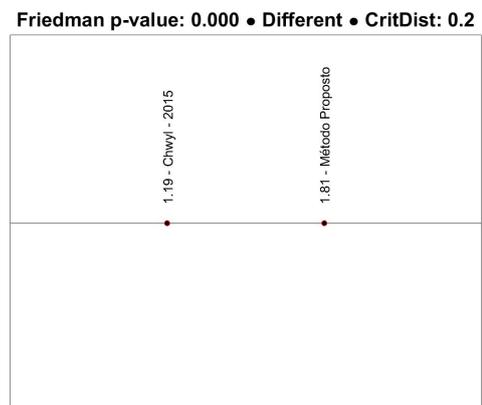
(a)



(b)



(c)

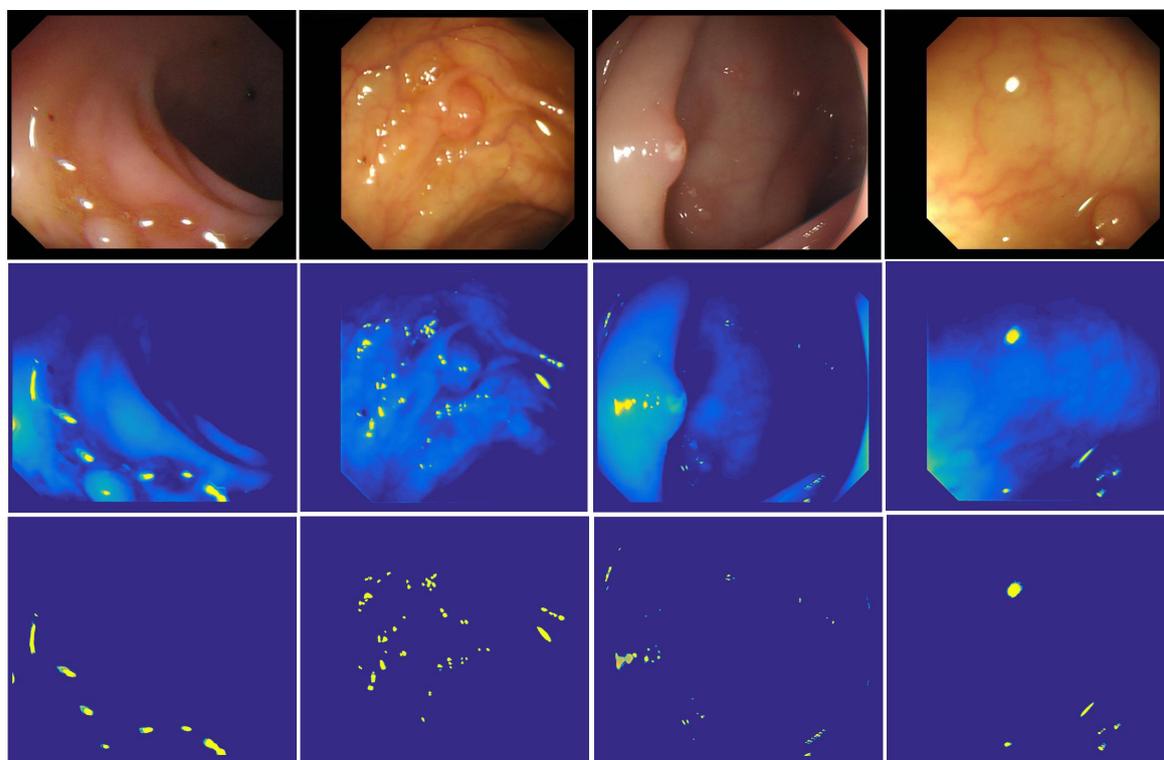


Fonte: Elaborada pela autora.

A segunda coluna da tabela indica a codificação dos algoritmos de cada método avaliado:

- M - código em Matlab (extensão *.m)
- P - código em Matlab (extensão *.p)
- MEX - código híbrido em Matlab (com chamada de funções desenvolvidas em c/c++)
- E - arquivo executável

Figura 49 – Resultados comparativos do método de segmentação. De cima para baixo: Imagem original, componente especular calculada pelo método de [Chwyl et al. \(2015\)](#) e componente especular calculada pelo nosso método de segmentação.



Fonte: Elaborada pela autora.

Na terceira coluna da tabela apresentamos o tempo médio em segundos de execução de cada método. Vale salientar que os métodos de [Arnold et al. \(2010\)](#) e [Meslouhi et al. \(2011\)](#), por se tratarem de um método de segmentação grosseira produzem resultados mais rápidos, uma vez que realizam a segmentação apenas com base em limiarização sobre valores de intensidade na imagem original.

5.2.4 Remoção e Preenchimento de Reflexos Especulares em Imagens Endoscópicas

Tanto a análise assistida por computador quanto a revisão manual de imagens endoscópicas são benéficas para um diagnóstico preciso, planejamento cirúrgico e assistência cirúrgica. Porém, como já citamos anteriormente, alguns algoritmos de análise de imagens são frequentemente afetados pela presença de reflexos especulares causados pela reflectividade especular das membranas mucosas dentro do corpo humano. Sendo assim, estes reflexos são conhecidamente um incômodo em diagnósticos médicos e fontes de erro em processos de análise ([CHWYL et al., 2015](#)). A detecção, remoção e preenchimento dessas regiões de reflexão especular tornam-se então um importante passo para garantir

Tabela 2 – Tempos de processamento dos métodos de segmentação de reflexos especulares comparados. Na coluna de códigos, M indica código em Matlab (extensão **.m*), P indica código em Matlab (extensão **.p*), MEX indica código híbrido em Matlab (com chamada de funções desenvolvidas em c/c++) e E indica arquivo executável.

Método	Código	Tempo de Execução (seg)
Arnold et al. (2010)	M	7.4
Meslouhi et al. (2011)	M	5.9
Chwyl et al. (2015)	P, MEX	31.5
Método Proposto	M	17.3

Fonte: Elaborada pela autora.

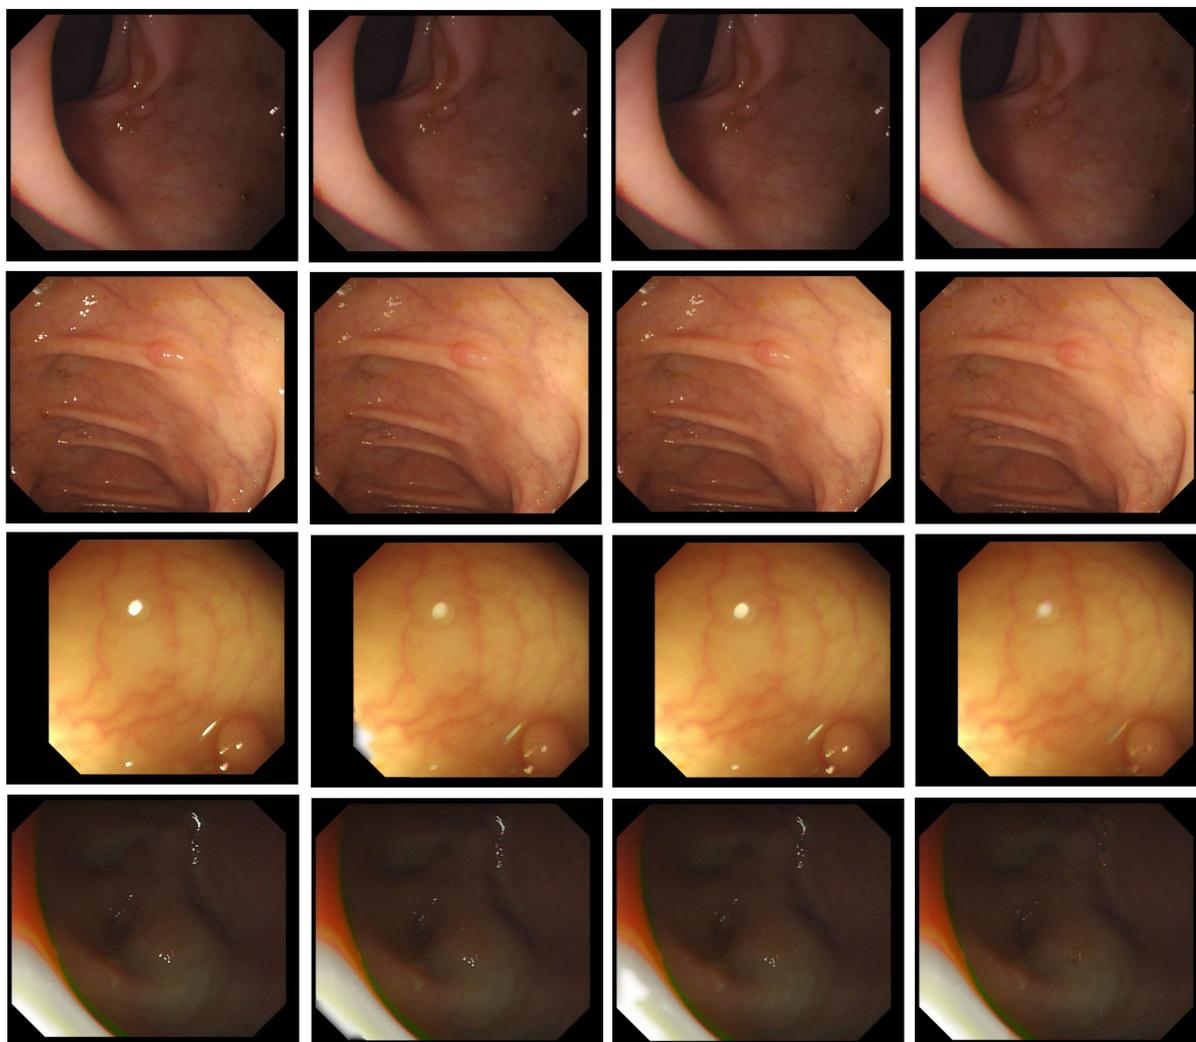
uma maior clareza de informação bem como o sucesso de algoritmos de análise e reconhecimento sobre essas imagens. Uma vez que a segmentação proposta nesta tese é tida como precisa, podemos assim garantir que em um processo de remoção desses reflexos, apenas informações sobre os mesmos sejam removidos da imagem, permanecendo as informações das proximidades dos reflexos e permanecendo também outras informações tais como vasos, dobras, etc.

Para mostrar a efetividade do método de segmentação que aqui propomos, apresentamos algumas imagens onde tais reflexos foram removidos da imagem utilizando o método de preenchimento (*inpainting*) proposto por [Shen e Chan \(2002\)](#). A [Figura 50](#) ilustra alguns resultados com a remoção destes reflexos utilizando nosso método de segmentação e os métodos propostos por [Arnold et al. \(2010\)](#) e [Meslouhi et al. \(2011\)](#). Em todos os casos, o mesmo algoritmo de preenchimento foi utilizado.

5.3 Validação do Método de Restauração de Imagens

Nesta seção nós apresentamos alguns experimentos relacionados ao método proposto de restauração de imagens com base no agrupamento e fusão de reflexos especulares em imagens de endoscopia óptica (ver [Capítulo 4](#)). Para a condução destes experimentos foram extraídas 30 imagens da base *CVC-ColonDB*, selecionadas através de amostragem aleatória simples. Uma vez que as imagens dessa base possuem, no geral, uma boa qualidade, estas foram degradadas uniformemente utilizando-se 5 PSFs diferentes, gerando-se assim um conjunto de 150 imagens degradadas de maneira invariante no espaço. A [Figura 51](#) mostra as PSFs utilizadas nesse processo de degradação, onde 4 dessas destas foram disponibilizadas por [Levin et al. \(2011\)](#) enquanto 1 foi criada para os propósitos desta tese.

Figura 50 – Remoção e preenchimento de regiões de reflexos especulares em imagens endoscópicas. Da esquerda para a direita: Imagem Original e componentes difusas após preenchimento das regiões de reflexos detectadas pelos métodos de [Arnold et al. \(2010\)](#), [Meslouhi et al. \(2011\)](#) e o método proposto, respectivamente.



Fonte: Elaborada pela autora.

Nós comparamos o método aqui desenvolvido com alguns dos mais citados e/ou mais recentes métodos do estado da arte que tiveram seus códigos fonte ou executáveis disponibilizados gratuitamente. Dessa forma, os experimentos foram realizados comparando-se método desenvolvido com os métodos de [Shan, Jia e Agarwala \(2008\)](#), [Xu e Jia \(2010\)](#), [Krishnan, Tay e Fergus \(2011\)](#), [Hua e Low \(2011\)](#), [Goldstein e Fattal \(2012\)](#), [Shearer, Gilbert e III \(2013\)](#), [Hu et al. \(2014\)](#) e [Pan et al. \(2016\)](#). É importante lembrar que os métodos de [Hua e Low \(2011\)](#) e [Hu et al. \(2014\)](#) usam reflexos especulares no processo de estimação da PSF da degradação a fim de promover a restauração da imagem. Vale salientar também que, ao contrário da maior parte dos métodos existentes no estado da arte, o método de estimação da PSF da degradação proposto por [Goldstein e Fattal](#)

Figura 51 – PSFs utilizadas na degradação das imagens do experimento: 4 delas foram disponibilizadas por [Levin et al. \(2011\)](#) e uma delas foi criada para os propósitos deste trabalho (a terceira da esquerda para a direita).



Fonte: Elaborada pela autora.

(2012) não realiza uma estimativa MAP, que envolve reconstruções repetidas da imagem nítida. Esse método estima a PSF com base em irregularidades estatísticas encontradas na densidade espectral da imagem a ser restaurada.

5.3.1 Parâmetros Utilizados

O processo da estimação da PSF é feita através do [algoritmo 4](#), sendo o parâmetro usado nesse processo o peso $\lambda = 0,004$. Já no processo de deconvolução não-cega utilizado na restauração da imagem (ver Subseção [4.2.5.1](#)), os parâmetros usados foram:

- $w_{tdeconv} = 0,02$ (parâmetro de peso para controlar a suavidade do processo de deconvolução)
- $w_{tderinging} = 5$ (parâmetro de peso para suprimir efeitos de ondulação na imagem)
- $denoise = 0$ (parâmetro que indica a remoção de possíveis ruídos impulsivos)
- $padding = 1$ (uso de *padding* na imagem durante a deconvolução)

5.3.2 Métricas do Experimento e Estatísticas

A métrica PV (*Perceptually-Validated Metric*) proposta por [Liu et al. \(2013\)](#) foi utilizada para avaliar e comparar a qualidade das imagens restauradas nesse experimento. Diferentemente de outras métricas tradicionais utilizadas, como a métrica SSIM (*Structural SIMilarity*) ([WANG et al., 2004](#)) e PSNR (*Peak signal-to-noise ratio*), esta métrica não é referenciada, ou seja, ela não requer acesso a imagens de referência para avaliar a qualidade da imagem. Além disto, a métrica PV foi desenvolvida com o objetivo específico de avaliar imagens restauradas após processo de borramento. No desenvolvimento da métrica PV, os autores conduziram um estudo no qual coletou-se de usuários diferentes avaliações sobre a qualidade visual de imagens que sofreram processos de restauração. Ao estudar os dados provenientes desses usuários, foram identificados os três artefatos mais comuns nesses tipos de imagens: ondulações, ruído e borramento residual. Dessa forma, no

desenvolvimento dessa métrica comparativa, os autores propuseram um meio de identificar e quantificar especificamente tais artefatos. Quanto mais alto for o valor resultante da aplicação dessa métrica, melhor é a qualidade da imagem restaurada.

Uma vez que os métodos de [Hua e Low \(2011\)](#) e [Hu et al. \(2014\)](#) também realizam a estimativa da PSF da degradação através de *highlights*, nós damos uma atenção especial a estes métodos quando o comparamos com nosso método proposto. Após obter os valores da métrica PV sobre as 150 imagens restauradas com o nosso método e os dois métodos citados acima, obtemos 3 amostras com tais valores. As diferenças estatísticas sobre estas 3 amostras são obtidas analisando-se suas variâncias. Após testes de normalidade sobre essas amostras (ver [Tabela 3](#), linhas 3 e 6), observamos que as mesmas não apresentavam distribuição aproximadamente normal, dessa forma a análise de variância foi realizada através do teste não-paramétrico de *Friedman* seguido do pós-teste de *Nemenyi* sob a justificativa de que tais amostras são pareadas.

Tabela 3 – Teste de normalidade sobre as amostras contendo os valores para a métrica PV.

Método	<i>p-value</i>
Shan, Jia e Agarwala (2008)	0,00327
Xu e Jia (2010)	0,00453
Hua e Low (2011)	0,00055
Krishnan, Tay e Fergus (2011)	0,00989
Goldstein e Fattal (2012)	0,00013
Shearer, Gilbert e III (2013)	0,00086
Hu et al. (2014)	0,00785
Pan et al. (2016)	0,00735
Método proposto	0,00111

Fonte: Elaborada pela autora.

A [Figura 52](#) mostra alguns exemplos de imagens restauradas pelo nosso método e a [Figura 53a](#) mostra o gráfico de frequência acumulada para cada uma das 3 amostras. A amostra com o valores da métrica para o nossos resultados compõe a curva mais a direita no gráfico, logo, este apresenta resultados mais altos para a métrica PV, o que implica em uma melhor performance. A [Figura 53b](#) mostra os *boxplots* para as 3 amostras analisadas. Em uma avaliação visual desses *boxplots* podemos perceber também que o método proposto apresenta valores mais altos para a métrica. O teste não-paramétrico de *Friedman* detecta diferenças significativas entre as amostras que são melhor interpretados após o ranqueamento dos resultados mostrado na [Figura 53c](#). De acordo com esse teste,

existe diferenças significativas entre os 3 métodos avaliados, sendo o método por nós proposto melhor ranqueado.

O método proposto foi comparado também aos métodos de [Shan, Jia e Agarwala \(2008\)](#), [Xu e Jia \(2010\)](#), [Shearer, Gilbert e III \(2013\)](#) e [Pan et al. \(2016\)](#). A [Figura 54a](#) mostra o gráfico de frequência acumulada das amostras contendo os valores da métrica PV calculados para cada método comparado. A [Figura 54b](#) mostra os *boxplots* para as mesmas amostras. O teste não-paramétrico de *Friedman* detecta as diferenças de variância entre as amostras e o resultado do ranqueamento das mesmas é mostrado na [Figura 54c](#). Como podemos observar, o teste indica que não existe diferenças estatísticas significativas entre o nosso método e o método de [Xu e Jia \(2010\)](#).

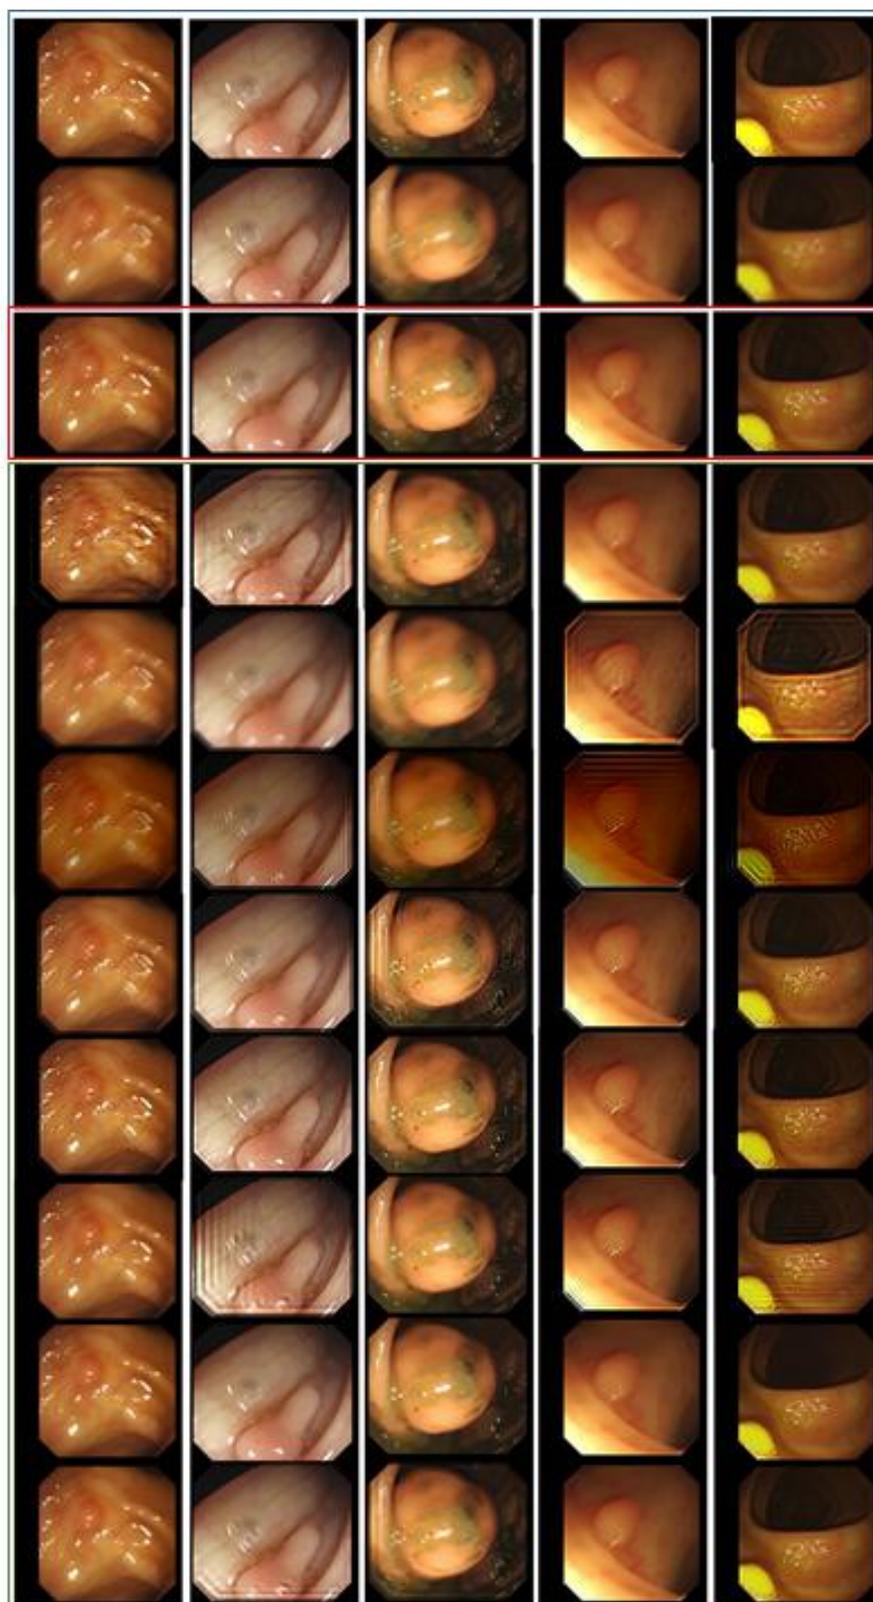
Em trabalho recente, [Lai et al. \(2016\)](#) apresentou um estudo comparativo entre técnicas de restauração de imagens, e mostrou que, dentro de um contexto de borramento invariante no espaço, o método de [Xu e Jia \(2010\)](#) apresentava os melhores resultados, quando comparado a outros 13 métodos do estado da arte. Em uma análise mais detalhada, é possível ver no *boxplot* da [Figura 54b](#) que o método [Xu e Jia \(2010\)](#) apresenta alguns *outliers* com valores muito baixos para a métrica PV (mais do que o método que propomos). Esse fato acontece basicamente por duas razões: (1) O método de [Xu e Jia \(2010\)](#) utiliza um mapa de arestas presentes na imagem como termo adicional para o problema de otimização clássico mostrado pela [Equação 4.16](#). Contudo, muitas imagens endoscópicas, diferentemente de imagens naturais, apresentam uma aparência mais uniforme com poucas regiões de alta frequência resultante do número reduzido de reflexos especulares, dobras, vasos, etc. Dessa forma, uma vez que o mapa de arestas possui poucas informações úteis, a restauração da imagem acaba não sendo muito bem sucedida. (2) Imagens endoscópicas também apresentam regiões muito saturadas, e o método de [Xu e Jia \(2010\)](#) não foi desenvolvido para lidar bem com imagens com altos níveis de saturação.

5.3.3 Tempos de Processamento

A [Tabela 4](#) apresenta uma lista com os tempos de processamento médios de execução dos métodos de segmentação aqui comparados. Nesta tabela apresentamos o tempo total para a restauração envolvendo os processos de segmentação, agrupamento e fusão dos reflexos especulares presentes na imagem. O tempo médio gasto em cada uma dessas etapas está descrito na [Tabela 5](#).

Diante dessas informações sobre tempos de processamento, podemos verificar que o custo de restauração da imagem pelo método proposto, partindo da PSF em potencial estimada através dos reflexos especulares presentes na imagem é consideravelmente menor que o custo do método no qual este se baseia ([PAN et al., 2016](#)), que por sua vez, faz uso da abordagem em multi-escala e de canais escuros como regularização adicional. De posse da PSF em potencial, o nosso método de restauração estima a PSF da degradação e

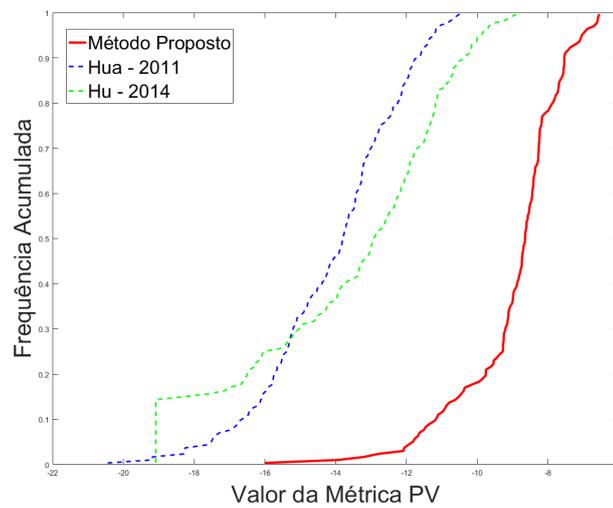
Figura 52 – Resultados comparativos dos métodos de restauração de imagens. De cima para baixo: Imagem nítida original e imagem degradada (marcadas em azul); Imagem restaurada pelo método proposto nessa tese (marcadas em vermelho); imagens restauradas pelos métodos de Hua e Low (2011), Pan et al. (2016), Goldstein e Fattal (2012), Krishnan, Tay e Fergus (2011), Shearer, Gilbert e III (2013), Shan, Jia e Agarwala (2008), Pan et al. (2016) e Xu e Jia (2010), respectivamente (marcadas em verde).



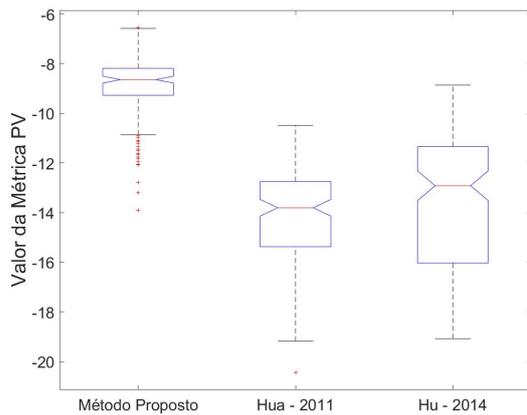
Fonte: Elaborada pela autora.

Figura 53 – Análise de variância para avaliar a similaridades entre as amostras contendo os valores da métrica PV. (a) Gráfico de frequência acumulada de cada uma das amostras; (b) *boxplots* para a distribuição das amostras; (c) Diferenças significantes entre as amostras pelo teste de *Friedman* e pós teste de *Nemenyi*.

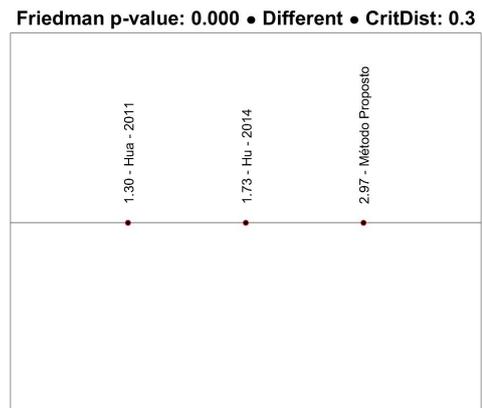
(a)



(b)



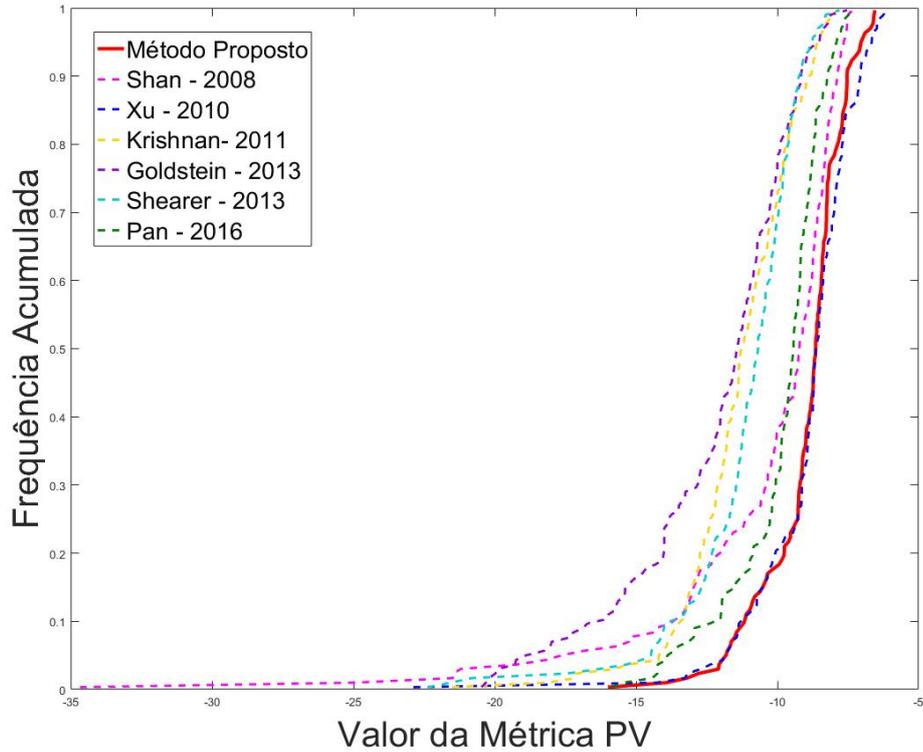
(c)



Fonte: Elaborada pela autora.

Figura 54 – Análise de variância para avaliar a similaridades entre as amostras contendo os valores da métrica PV. (a) Gráfico de frequência acumulada de cada uma das amostras; (b) *boxplots* para a distribuição das amostras; (c) Diferenças significantes entre as amostras pelo teste de *Friedman* e pós teste de *Nemenyi*.

(a)



(b)

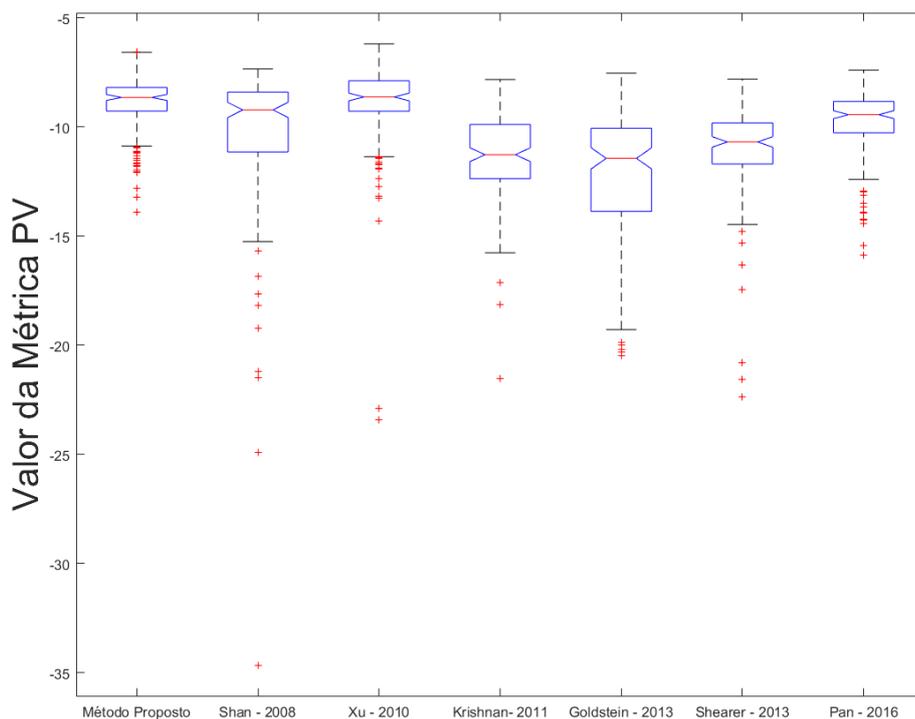
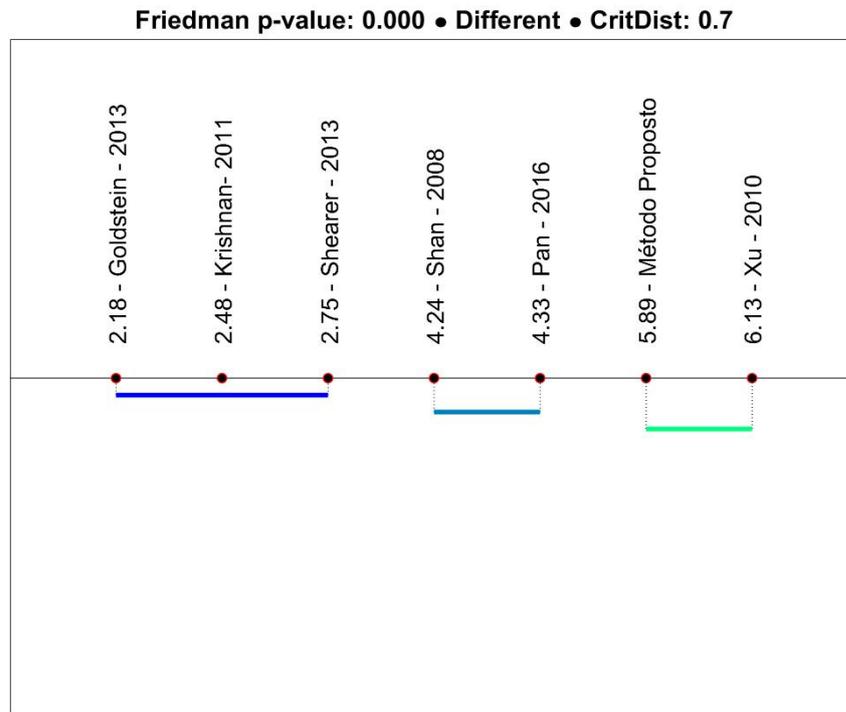


Figura 54

(c)



Fonte: Elaborada pela autora.

restaura a imagem em um tempo médio de aproximadamente 42 segundos (linhas 6 e 7 da Tabela 5), enquanto que o método de Pan et al. (2016) o fazem aproximadamente 85 segundos (linha 7 da Tabela 4).

Vale observar também que o método de Xu e Jia (2010) utilizado, uma vez que foi desenvolvido em C/C++, apresenta um menor tempo de processamento em detrimento ao nosso método, totalmente implementado Matlab, uma linguagem de computação científica que por sua vez, não prioriza o bom desempenho em termos de custos computacionais. Não foram utilizados também, no desenvolvimento do nosso método, recursos à GPU.

5.4 Detecção Automática de Pólipos em Imagens de Colonoscopia óptica Restauradas

No ano de 2016, o câncer de cólon e reto foi estimado como o terceiro tipo de câncer mais comum a afetar pessoas nos EUA, com uma estimativa do número de mortes de 49.190 (SIEGEL; MILLER; JEMAL, 2016). Segundo Instituto Nacional do Câncer (INCA), no

Tabela 4 – Tempos de processamento para os métodos comparados de restauração de imagens. Na coluna de códigos, M indica código em Matlab (extensão *.m), P indica código em Matlab (extensão *.p), MEX indica código híbrido em Matlab (com chamada de funções desenvolvidas em c/c++) e E indica arquivo executável.

Método	Código	Tempo de Execução (seg)
Shan, Jia e Agarwala (2008)	E	95
Xu e Jia (2010)	E	17.9
Hua e Low (2011)	M	16.6
Krishnan, Tay e Fergus (2011)	M	130
Goldstein e Fattal (2012)	M,MEX	114.8
Shearer, Gilbert e III (2013)	M	198.9
Hu et al. (2014)	M,P	235
Pan et al. (2016)	M	85.2
Método proposto	M	79.4

Fonte: Elaborada pela autora.

Nota – Todos as imagens restauradas pelo método de [Xu e Jia \(2010\)](#) tiveram a opção de redução de ruídos desabilitada.

Nota – O tempo de execução de 16.6 do método de [Hua e Low \(2011\)](#), inclui a assistência do usuário na marcação do *highlight* usado para estimar a PDF da degradação. O método demora em média 7.7 segundos para restaurar a imagem, excluindo-se a interferência do usuário.

Brasil, no mesmo ano, estimou-se 16.660 casos novos de câncer de cólon e reto em homens e de 17.620 em mulheres. Esses valores correspondem a um risco estimado de 16,84 casos novos a cada 100 mil homens e 17,10 para cada 100 mil mulheres ([INCA, 2016](#)). O seu desenvolvimento é o resultado da transformação do epitélio colônico normal para pólipos adenomatosos e, subsequentemente, câncer. A progressão é lenta, possivelmente envolvendo vários anos, e seguindo-se número considerável de alterações genéticas, recentemente caracterizadas. Os procedimentos endoscópicos permitem o diagnóstico e ressecção dos pólipos quando ainda benignos. Com isso há diminuição, comprovada da incidência do câncer colorretal. Porém a detecção de pólipos em procedimentos de colonoscopia óptica não é uma tarefa infalível. Um número significativo de pólipos tanto planos quanto pedunculados podem não ser detectados pelo médico durante o procedimento. A alta taxa de detecção de pólipos, conforme apontado por [Hewett, Kahi e Rex \(2010\)](#), requer um alto nível de atenção, vigilância e sensibilidade às características visuais dos pólipos por parte dos médicos e essas qualidades só são obtidas após anos de prática e experiência.

Tabela 5 – Tempos de processamento para cada uma das etapas do método de restauração proposto. Na coluna de códigos, M indica código em Matlab (extensão **.m*), P indica código em Matlab (extensão **.p*), MEX indica código híbrido em Matlab (com chamada de funções desenvolvidas em c/c++) e E indica arquivo executável.

Etapa	Código	Tempo de Execução (seg)
Segmentação de reflexos especulares	M	34.9
Extração de características	M	0.2
Agrupamento de reflexos especulares	M	0.7
Fusão de reflexos especulares	M	0.2
Escolha da melhor PSF em potencial	M	1.1
Estimação da PSF da degradação	M	31.4
Deconvolução não-cega	E	10.9
Método Completo	-	79.4

Fonte: Elaborada pela autora.

Devido a este fator, muitas pesquisas têm sido desenvolvidas com o objetivo de utilizar recursos de processamento de imagens e visão computacional para auxiliar na detecção de pólipos em imagens de colonoscopia óptica (BERNAL; SANCHEZ; VILARINO, 2012; TAJBAKSH; GURUDU; LIANG, 2013; TAJBAKSH; GURUDU; LIANG, 2016).

Uma vez que todas as imagens da base *CVC-ColonDB* apresenta pólipos, nós aplicamos o método de detecção de pólipos proposto por Tajbakhsh, Gurudu e Liang (2013) sobre as 30 imagens originais não degradadas utilizadas no experimento de validação do método de restauração (ver Seção 5.3), sobre as imagens degradadas e sobre as imagens restauradas pelo método que propomos nesta tese.

Em seu trabalho, Tajbakhsh, Gurudu e Liang (2013) propuseram um método automático de detecção de pólipos onde, dada uma imagem de colonoscopia, a ideia principal é identificar os *pixels* de borda que se encontram no limite de pólipos e, em seguida, determinar a localização de um pólipo a partir das bordas identificadas. Para atingir seus objetivos, os autores utilizaram métodos de extração de característica das regiões de bordas de pólipos e outras informações e métodos de classificação supervisionado com base em florestas aleatórias (BREIMAN, 2001).

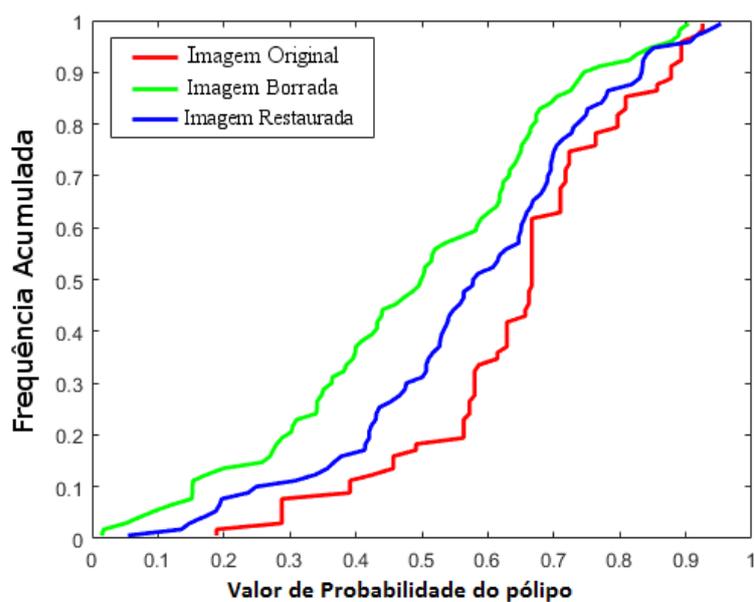
Das 30 imagens originais usadas no experimento da Seção 5.3, o algoritmo de detecção de Tajbakhsh, Gurudu e Liang (2013) não conseguiu detectar pólipos em 2 delas, sendo assim essas imagens foram excluídas dessa avaliação, ficando apenas 28 imagens originais. Das 28 imagens, geramos uma amostra de 140 imagens degradadas pelas 5 PSF usadas neste trabalho e mostradas na Figura 51. Logo, de posse dessas 140 imagens

degradadas por borramento e 140 imagens restauradas, o saldo pra detecção de pólipos nesse experimento foi:

- Em 10 imagens foi possível detectar corretamente o pólipo na imagem restaurada enquanto não foi possível detectá-lo corretamente na imagem degradada por borramento.
- Em 3 imagens não foi possível detectar corretamente o pólipo na imagem degradada por borramento e na respectiva imagem restaurada.
- Em 4 imagens foi possível detectar corretamente o pólipo degradada por borramento mas não foi possível detectar corretamente na respectiva imagem restaurada. Isso acontece devido a uma restauração mal sucedida, onde a imagem apresenta artefatos de ondulação.
- Em 123 imagens foi possível detectar o pólipo corretamente nas duas imagens (degradada por borramento e restaurada), porém, em 76 dessas 123 imagens (cerca de 61,78% dos casos), o tumor foi detectado pelo classificador com valores de probabilidade maior na imagem restaurada do que na imagem degradada.

A [Figura 55](#) mostra o gráfico de frequência acumulada para as 76 imagens citadas acima. O gráfico mostra os valores de probabilidade dos pólipos na imagem original, na imagem degradada por borramento e na imagem restaurada. A curva mais a direita indica valores de probabilidades mais altos.

Figura 55 – Gráfico de frequência acumulada para a detecção de pólipos nas imagens originais, degradadas e restauradas.



Fonte: Elaborada pela autora.

6 CONSIDERAÇÕES FINAIS

O foco deste trabalho foi a elaboração e desenvolvimento de um método de restauração cega de imagens endoscópicas, na qual a PSF da degradação é estimada através do agrupamento e fusão de reflexos especulares, um tipo de degradação muito comum nesse tipo de imagem. Para tanto, este trabalho foi dividido em duas etapas principais: inicialmente foi desenvolvido um método de segmentação precisa de reflexos especulares cujo resultado é a criação de uma componente especular da imagem e posteriormente, foi desenvolvido um método de restauração cega de imagens onde a PSF é estimada através do agrupamento e fusão dos reflexos presentes na componente especular resultante do processo de segmentação.

No método de segmentação proposto, apresentamos um novo meio de segmentar de maneira precisa os reflexos presentes em imagens de endoscopia óptica com base no uso de um algoritmo de decomposição matricial. Chamamos tal método de “preciso”, pois diferentemente da maior parte dos trabalhos do estado da arte, que geram imagens binárias contendo os reflexos detectados, este gera como resultado da segmentação uma imagem em tons de cinza contendo as informações de opacidade dos reflexos especulares, tal qual uma separação de *foreground* e *background* do tipo *matting* realizada sobre a imagem.

No método de restauração cega proposto, apresentamos uma nova forma de se estimar a PSF da degradação através do agrupamento e fusão dos reflexos especulares presentes na componente especular resultante da etapa anterior. Provamos que os reflexos especulares presentes na imagem, uma vez que identificados e segmentados, podem ser usados de maneira efetiva na estimação da PSF da degradação sofrida por ua imagem. Observamos que na maior parte dos experimentos realizados, a fusão destes reflexos gera uma PSF em potencial próxima a PSF real do sistema, e que a mesma não fere os pré-requisitos de que a PSF estimada deve ser esparsa, positiva e com um tamanho pequeno quando comparada à imagem sendo restaurada.

Os experimentos realizados na validação de ambos os métodos mostram que estes apresentam um desempenho similar ou superior aos resultados dos métodos presentes no estado da arte.

6.1 Contribuições

Em relação às contribuições oferecidas por esse trabalho, podemos citá-las em dois pontos distintos: segmentação de reflexos especulares em imagens de endoscopia óptica e restauração destas mesmas imagens quando degradadas por movimentação de câmera.

Quanto ao método de segmentação de reflexos especulares proposto, a contribuição se deu na forma precisa que tais reflexos são segmentados. Em imagens de endoscopia óptica, uma vez que estes reflexos são conhecidamente um incômodo em diagnósticos médicos e fontes de erro em processos de análise (CHWYL et al., 2015), a detecção e remoção dos mesmo torna-se um importante passo para garantir uma maior clareza destas imagens. Uma vez que a segmentação proposta é precisa, podemos assim garantir também que apenas informações sobre os reflexos são removidos da imagem, permanecendo na mesmas informações das proximidades dos reflexos e permanecendo também outras informações tais como vasos, dobras, etc. O processo de segmentação proposto, além de ser um passo inicial para a remoção dos reflexos especulares também mostra-se eficaz para a estimação da PSF de degradação de possíveis borrachamentos por movimentação de câmera que tais imagens possam sofrer, considerando-se que este tipo de degradação é também bastante comum nesse tipo de imagem.

Quanto ao método de restauração cega de imagens endoscópicas, dentro de um contexto de borrachamento uniforme, provamos que podemos fazer uso de reflexos especulares como informação *a priori* para estimar a PSF real da degradação causada por movimentação de câmera, bem como mostramos que a estimação desta PSF através do agrupamento e fusão dos reflexos presentes na imagem apresenta um desempenho superior aos métodos do estado da arte que os utilizam de forma isolada para estimar a PSF da degradação. Mostramos também que imagens endoscópicas restauradas pelo nosso método tem maiores chances de ter informações como pólipos detectadas por meio de algoritmos de detecção automática.

6.2 Limitações

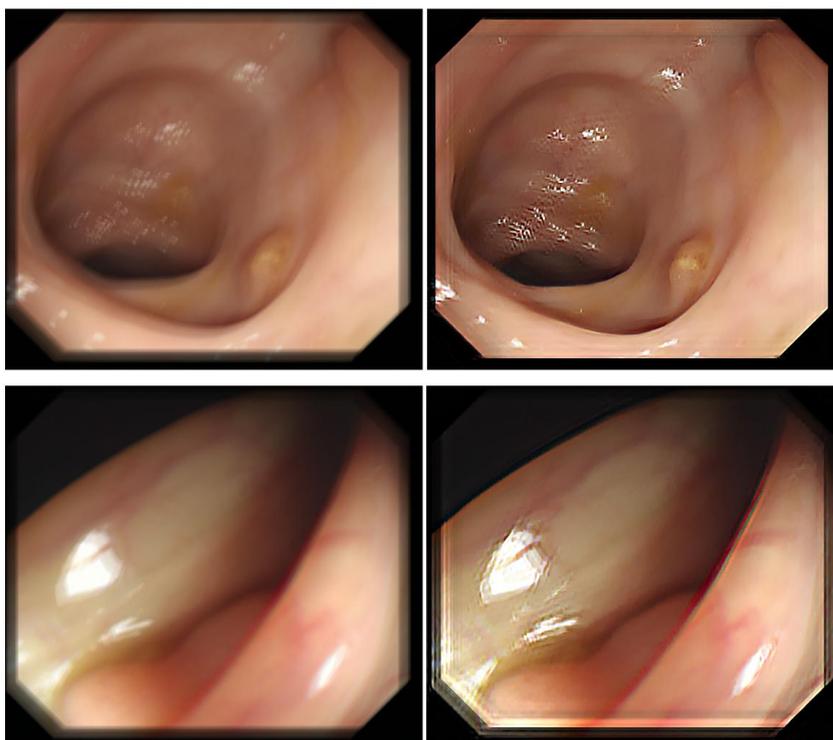
O método de restauração que propomos neste trabalho tende a não ser bem sucedida em alguma situações como as listadas abaixo:

1. A imagem não possui reflexos especulares em sua composição;
2. A imagem possui reflexos especulares, porém estes encontram-se demasiadamente próximos uns dos outros, e durante o borrachamento, a união dos mesmos não permite uma boa segmentação;
3. A imagem possui reflexos especulares, porém estes tem uma área demasiadamente grande para produzir boas PSFs em potencial. Quando a área dos reflexos é grande, esta fere o pre-requisito de que a PSF estimada deve ter suporte pequeno quando comparado à imagem a ser restaurada.

O primeiro caso não ocorreu em nossos experimentos, uma vez que *highlights* causados por reflexos especulares são muito comuns nesse tipo de imagem. Porém a

possibilidade da ausência destes reflexos deve ser considerada. As limitações referentes aos dois últimos casos são ilustradas pela [Figura 56](#). Na primeira linha da figura temos um caso de reflexos especulares muito próximos que causam artefatos de ondulação na imagem restaurada. Na segunda linha da figura vemos um caso onde a imagem contém reflexos muito grandes, que não são úteis na estimativa da PSF, gerando também muitos artefatos de ondulação na imagem.

Figura 56 – Limitações do método de restauração proposto. Da esquerda para a direita: Imagem degradada por borrramento e imagem restaurada.



Fonte: Elaborada pela autora.

6.3 Trabalhos Futuros

Como trabalhos futuros relacionados a esta tese, intencionamos verificar a viabilidade de uma possível extensão do nosso método de restauração de imagens voltada para tratar degradações variantes no espaço, onde o borramento seja “natural”, ou seja, proveniente do movimento do endoscópio. Dessa forma, podemos justificar o uso de PSFs estimadas a partir de reflexos especulares também em um contexto de borramento não uniforme, uma vez que reflexos posicionados em diferentes regiões da imagem carregam informações locais sobre a degradação naquela região. Objetivamos também estender a restauração para vídeos de endoscopia óptica e desenvolver um método de preenchimento das regiões de reflexos, onde as informações pertinentes a estas regiões sejam recuperadas de quadros (*frames*) consecutivos.

Pretendemos também evoluir essa técnica de restauração de imagens para agrupar e fundir PSFs resultantes de outros procedimentos que não sejam baseados no uso exclusivo de *highlights*, verificando assim o quanto o método de fusão aqui desenvolvido, quando aplicado a estas PSFs, pode ser úteis no processo de restauração de imagens naturais.

por fim, os próximos passos para dar continuidade ao método de restauração proposto nesta tese devem incluir meios de melhorar os tempos de processamento tanto do método de segmentação quanto do método de restauração proposto através de uma implementação dos mesmos em linguagens que priorizem tal custo, quanto através do uso de recursos como GPU.

REFERÊNCIAS

- AL-AMEEN, Z.; SULONG, G. Deblurring computed tomography medical images using a novel amended landweber algorithm. *Interdisciplinary Sciences: Computational Life Sciences*, v. 7, n. 3, p. 319–325, 2015. Citado na página 19.
- AMIZIC, B.; MOLINA, R.; KATSAGGELOS, A. K. Sparse bayesian blind image deconvolution with parameter estimation. *EURASIP Journal on Image and Video Processing*, v. 2012, p. 1–15, 2012. Citado na página 45.
- ARAVKIN, A. Y. et al. A variational approach to stable principal component pursuit. In: ZHANG, N. L.; TIAN, J. (Ed.). *UAI*. [S.l.]: AUAI Press, 2014. p. 32–41. ISBN 978-0-9749039-1-0. Citado na página 56.
- ARNOLD, M. et al. Automatic segmentation and inpainting of specular highlights for endoscopic imaging. *J. Image Video Process.*, Hindawi Publishing Corp., New York, NY, United States, v. 2010, p. 9:1–9:12, jan. 2010. ISSN 1687-5176. Citado 11 vezes nas páginas 22, 29, 52, 84, 85, 87, 88, 90, 93, 94 e 95.
- ATTIVISSIMO, F. et al. A technique to improve the image quality in computer tomography. *IEEE Transactions on Instrumentation and Measurement*, v. 59, n. 5, p. 1251–1257, May 2010. ISSN 0018-9456. Citado na página 19.
- BAUER, W.; WESTFALL, G.; DIAS, H. *Física para Universitários: Óptica e Física Moderna*. Bookman Editora, 2013. ISBN 9788580552034. Disponível em: <<https://books.google.com.br/books?id=irZlAgAAQBAJ>>. Citado 2 vezes nas páginas 21 e 27.
- BENICHOUX, A.; VINCENT, E.; GRIBONVAL, R. A fundamental pitfall in blind deconvolution with sparse and shift-invariant priors. In: *Acoustics, Speech and Signal Processing (ICASSP), IEEE International Conference on*. [S.l.: s.n.], 2013. p. 6108–6112. Citado na página 40.
- BERNAL, J.; SÁNCHEZ, J.; VILARINO, F. *Cvc-colondb: A database for assessment of polyp detection, Database*. 2012. Disponível em: <<http://mv.cvc.uab.es/projects/colon-qa/cvccolondb>>. Citado 5 vezes nas páginas 23, 28, 51, 84 e 85.
- BERNAL, J.; SANCHEZ, J.; VILARINO, F. Towards automatic polyp detection with a polyp appearance model. *Pattern Recognition*, v. 45, n. 9, p. 3166 – 3182, 2012. Citado 3 vezes nas páginas 22, 25 e 104.
- BEZDEK, J. C. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Norwell, MA, USA: Kluwer Academic Publishers, 1981. Citado na página 70.
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001. Citado na página 104.
- BUSTOS, O. H.; FRERY, A. C. A contribution to the study of markovian degraded images: an extension of a theorem by geman and geman. *Computational and Applied Mathematics*, v. 11, n. 1, p. 17–29, 281–285, 1992. Citado na página 31.

- CAI, J.-F.; CHAN, R. H.; NIKOLOVA, M. Fast two-phase image deblurring under impulse noise. *Journal of Mathematical Imaging and Vision*, v. 36, n. 1, p. 46–53, 2009. Citado na página 40.
- CAO, Y. et al. Computer-aided detection of diagnostic and therapeutic operations in colonoscopy videos. *Biomedical Engineering, IEEE Transactions on*, v. 54, n. 7, p. 1268–1279, July 2007. Citado na página 29.
- CHAKRABORTY, B.; MARCINCZAK, J. M.; GRIGAT, R.-R. Classification of weak specular reflections in laparoscopic images. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *SPIE Medical Imaging*. [S.l.], 2014. p. 90353I–90353I. Citado na página 29.
- CHAN, R.; DONG, Y.; HINTERMULLER, M. An efficient two-phase L^1 -tv method for restoring blurred images with impulse noise. *Image Processing, IEEE Transactions on*, v. 19, n. 7, p. 1731–1739, July 2010. Citado 2 vezes nas páginas 40 e 46.
- CHO, S. et al. Registration based non-uniform motion deblurring. *Computer Graphics Forum*, Blackwell Publishing Ltd, v. 31, n. 7, p. 2183–2192, 2012. Citado na página 35.
- CHO, S.; LEE, S. Fast motion deblurring. In: *ACM SIGGRAPH Asia 2009 Papers*. New York, NY, USA: ACM, 2009. (SIGGRAPH Asia '09), p. 145:1–145:8. Citado 4 vezes nas páginas 35, 39, 40 e 45.
- CHO, S.; WANG, J.; LEE, S. Handling outliers in non-blind image deconvolution. In: *Proc. IEEE International Conference on Computer Vision (ICCV 2011)*. [S.l.: s.n.], 2011. p. 1–8. Citado 3 vezes nas páginas 19, 46 e 50.
- CHWYL, B. et al. Specular reflectance suppression in endoscopic imagery via stochastic bayesian estimation. In: KAMEL, M.; CAMPILHO, A. J. C. (Ed.). *ICIAR*. Niagara Falls, Canada: Springer, 2015. (Lecture Notes in Computer Science, v. 9164), p. 385–393. ISBN 978-3-319-20800-8. Citado 11 vezes nas páginas 10, 30, 84, 86, 88, 89, 90, 91, 93, 94 e 108.
- DEBNATH, A. et al. Deblurring and denoising of magnetic resonance images using blind deconvolution method. *International Journal of Computer Applications*, v. 81, n. 10, p. 7–12, November 2013. Citado na página 19.
- DELBRACIO, M.; SAPIRO, G. Burst deblurring: Removing camera shake through fourier burst accumulation. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2015. p. 2385–2393. ISSN 1063-6919. Citado na página 18.
- DING, X.; HE, L.; CARIN, L. Bayesian robust principal component analysis. *IEEE Trans. Image Processing*, v. 20, n. 12, p. 3419–3430, 2011. Citado na página 56.
- FERGUS, R. et al. Removing camera shake from a single photograph. *ACM Trans. Graph.*, ACM, New York, NY, USA, v. 25, n. 3, p. 787–794, jul. 2006. ISSN 0730-0301. Citado 8 vezes nas páginas 18, 19, 35, 41, 42, 43, 45 e 79.
- FRIEDMAN, M. A comparison of alternative tests of significance for the problem of m rankings. *Ann. Math. Statist.*, The Institute of Mathematical Statistics, v. 11, n. 1, p. 86–92, 03 1940. Citado na página 87.

- GAN, C.; WANG, X.; WANG, Y. Human motion segmentation by rpca with augmented lagrange multiplier. In: *Audio, Language and Image Processing (ICALIP), International Conference on*. [S.l.: s.n.], 2012. p. 379–383. Citado na página 52.
- GANESH, A. et al. Fast algorithms for recovering a corrupted low-rank matrix. In: *Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP), 2009 3rd IEEE International Workshop on*. [S.l.: s.n.], 2009. p. 213–216. Citado 6 vezes nas páginas 30, 52, 53, 54, 55 e 56.
- GAST, J.; SELLENT, A.; ROTH, S. Parametric object motion from blur. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2016. p. 1846–1854. Citado na página 37.
- GEMAN, S.; GEMAN, D. Stochastic relaxation, gibbs distributions, and the bayesian restoration of images. *IEEE Trans. Pattern Anal. Mach. Intell.*, IEEE Computer Society, Washington, DC, USA, v. 6, n. 6, p. 721–741, nov. 1984. Citado na página 31.
- GHOSH, T. et al. A statistical feature based novel method to detect bleeding in wireless capsule endoscopy images. In: *2014 International Conference on Informatics, Electronics Vision (ICIEV)*. [S.l.: s.n.], 2014. p. 1–4. Citado 2 vezes nas páginas 22 e 25.
- GOLDSTEIN, A.; FATTAL, R. Blur-kernel estimation from spectral irregularities. In: *Proceedings of the 12th European Conference on Computer Vision - Volume Part V*. Berlin, Heidelberg: Springer-Verlag, 2012. (ECCV'12), p. 622–635. Citado 8 vezes nas páginas 18, 49, 77, 95, 96, 97, 99 e 103.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006. ISBN 013168728X. Citado na página 31.
- GUREYEV, T. et al. Image deblurring by means of defocus. *Optics Communications*, v. 240, n. 1–3, p. 81 – 88, 2004. Citado na página 42.
- HARMELING, S.; MICHAEL, H.; SCHÖLKOPF, B. Space-variant single-image blind deconvolution for removing camera shake. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2010. p. 829–837. Citado na página 37.
- HARTIGAN, J. A.; WONG, M. A. Algorithm AS 136: A k-means clustering algorithm. *Applied Statistics*, Blackwell Publishing for the Royal Statistical Society, v. 28, n. 1, p. 100–108, 1979. Citado na página 70.
- HEGENBART, S.; UHL, A.; VECSEI, A. Impact of endoscopic image degradations on lbp based features using one-class svm for classification of celiac disease. In: *Image and Signal Processing and Analysis (ISPA), 7th International Symposium on*. [S.l.: s.n.], 2011. p. 715–720. Citado 2 vezes nas páginas 22 e 55.
- HEWETT, D. G.; KAHI, C. J.; REX, D. K. Does colonoscopy work? *Journal of the National Comprehensive Cancer Network*, Harborside Press, LLC, v. 8, n. 1, p. 67–77, 2010. Citado na página 103.
- HIRSCH, M. et al. Fast removal of non-uniform camera shake. In: *Proceedings of the 2011 International Conference on Computer Vision*. Washington, DC, USA: IEEE Computer Society, 2011. (ICCV '11), p. 463–470. ISBN 978-1-4577-1101-5. Citado na página 37.

- HU, Z. et al. Deblurring low-light images with light streaks. In: *Computer Vision and Pattern Recognition (CVPR), IEEE Conference on*. [S.l.: s.n.], 2014. p. 3382–3389. Citado 14 vezes nas páginas 22, 29, 35, 45, 48, 49, 50, 62, 66, 77, 79, 95, 97 e 103.
- HUA, B.-S.; LOW, K.-L. Interactive motion deblurring using light streaks. In: *Image Processing (ICIP), 18th IEEE International Conference on*. [S.l.: s.n.], 2011. p. 1553–1556. Citado 10 vezes nas páginas 22, 29, 45, 46, 62, 79, 95, 97, 99 e 103.
- HYVRINEN, A.; HURRI, J.; HOYER, P. O. *Natural Image Statistics: A Probabilistic Approach to Early Computational Vision*. 1st. ed. [S.l.]: Springer Publishing Company, Incorporated, 2009. ISBN 1848824904, 9781848824904. Citado na página 44.
- INCA. *Instituto Nacional do Câncer*. 2016. Disponível em: <<http://www.inca.gov.br/estimativa/2016/tabelaestados.asp?UF=BR>>. Citado na página 103.
- JOSHI, N. et al. Image deblurring using inertial measurement sensors. *ACM Trans. Graph.*, ACM, New York, NY, USA, v. 29, n. 4, p. 30:1–30:9, jul. 2010. Citado na página 35.
- KARAPETYAN, G.; SARUKHANYAN, H. Automatic detection and concealment of specular reflections for endoscopic images. In: *Computer Science and Information Technologies (CSIT), 2013*. [S.l.: s.n.], 2013. p. 1–8. Citado na página 29.
- KENIG, T.; KAM, Z.; FEUER, A. Blind image deconvolution using machine learning for three-dimensional microscopy. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 32, n. 12, p. 2191–2204, Dec 2010. Citado na página 40.
- KRISHNAN, D.; FERGUS, R. Fast image deconvolution using hyper-laplacian priors. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2009. p. 1033–1041. Citado 2 vezes nas páginas 42 e 43.
- KRISHNAN, D.; TAY, T.; FERGUS, R. Blind deconvolution using a normalized sparsity measure. In: *CVPR 2011*. [S.l.: s.n.], 2011. p. 233–240. Citado 7 vezes nas páginas 40, 42, 78, 95, 97, 99 e 103.
- LAI, W.-S. et al. A comparative study for single image blind deblurring. In: *CVPR*. Las Vegas, Nevada, USA: IEEE Computer Society, 2016. p. 1701–1709. ISBN 978-1-4673-8851-1. Citado na página 98.
- LE, C. et al. Restoration of defocus blur image based on global phase coherence. In: *Image and Signal Processing. CISP. 2nd International Congress on*. [S.l.: s.n.], 2009. p. 1–5. Citado 2 vezes nas páginas 35 e 36.
- LEVIN, A. Blind motion deblurring using image statistics. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2006. p. 841–848. Citado na página 37.
- LEVIN, A. et al. Image and depth from a conventional camera with a coded aperture. *ACM Trans. Graph.*, ACM, New York, NY, USA, v. 26, n. 3, jul. 2007. Citado na página 42.
- LEVIN, A.; LISCHINSKI, D.; WEISS, Y. A closed-form solution to natural image matting. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 30, n. 2, p. 228–242, Feb 2008. Citado 4 vezes nas páginas 46, 47, 48 e 52.

- LEVIN, A. et al. Understanding and evaluating blind deconvolution algorithms. In: *Computer Vision and Pattern Recognition. CVPR. IEEE Conference on*. [S.l.: s.n.], 2009. p. 1964–1971. Citado 7 vezes nas páginas 32, 35, 38, 42, 44, 45 e 67.
- LEVIN, A. et al. Efficient marginal likelihood optimization in blind deconvolution. In: *Computer Vision and Pattern Recognition (CVPR), IEEE Conference on*. [S.l.: s.n.], 2011. p. 2657–2664. Citado 6 vezes nas páginas 19, 44, 45, 50, 94 e 96.
- LIU, H.; LU, W. S.; MENG, M. Q. H. De-blurring wireless capsule endoscopy images by total variation minimization. In: *Communications, Computers and Signal Processing (PacRim), IEEE Pacific Rim Conference on*. [S.l.: s.n.], 2011. p. 102–106. Citado na página 22.
- LIU, X. et al. Image deblurring based on light streak shape. *Journal of Electronic Imaging*, v. 25, n. 2, 2016. Citado 4 vezes nas páginas 22, 29, 45 e 62.
- LIU, Y. et al. A no-reference metric for evaluating the quality of motion deblurring. *ACM Trans. Graph.*, v. 32, n. 6, p. 175, 2013. Citado na página 96.
- LOFTS, G. *Jacaranda Physics*. John Wiley & Sons Australia, Limited, 2008. (Jacaranda Physics Series). ISBN 9780731408191. Disponível em: <<https://books.google.com.au/books?id=QkCONwAACAAJ>>. Citado 2 vezes nas páginas 20 e 21.
- LUCY, L. B. An iterative technique for the rectification of observed distributions. *The astronomical journal*, v. 79, p. 745, 1974. Citado na página 50.
- M.A., F. E. Xxii. on a new method of reducing observations relating to several quantities. *Philosophical Magazine Series 5*, v. 25, n. 154, p. 184–191, 1888. Citado na página 77.
- MA, J.; DIMET, F.-X. L. Deblurring from highly incomplete measurements for remote sensing. *Geoscience and Remote Sensing, IEEE Transactions on*, v. 47, n. 3, p. 792–802, March 2009. Citado na página 18.
- MA, L. et al. A dictionary learning approach for poisson image deblurring. *Medical Imaging, IEEE Transactions on*, v. 32, n. 7, p. 1277–1289, July 2013. Citado na página 40.
- MAI, L.; LIU, F. Kernel fusion for better image deblurring. In: *Computer Vision and Pattern Recognition. CVPR*. [S.l.]: IEEE Computer Society, 2015. p. 371–380. Citado 2 vezes nas páginas 64 e 75.
- MARRUGO, A. G. et al. Restoration of retinal images with space-variant blur. *Journal of Biomedical Optics*, v. 19, n. 1, p. 016023, 2014. Citado na página 19.
- MARRUGO, A. G. et al. Retinal image restoration by means of blind deconvolution. *Journal of Biomedical Optics*, v. 16, n. 11, p. 116016–116016–11, 2011. Citado na página 19.
- MESLOUHI, O. et al. Automatic detection and inpainting of specular reflections for colposcopic images. *Central European Journal of Computer Science*, v. 1, n. 3, p. 341–354, 2011. Citado 10 vezes nas páginas 22, 29, 84, 85, 87, 88, 90, 93, 94 e 95.

- MICHAELI, T.; IRANI, M. Blind deblurring using internal patch recurrence. In: _____. *Computer Vision – ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part III*. Cham: Springer International Publishing, 2014. p. 783–798. Citado na página 19.
- NEMENYI, P. *Distribution-free Multiple Comparisons*. [S.l.: s.n.], 1963. Citado na página 87.
- NIKOLOVA, M. Minimizers of cost-functions involving nonsmooth data-fidelity terms. application to the processing of outliers. *SIAM Journal on Numerical Analysis*, SIAM, v. 40, n. 3, p. 965–994, 2002. Citado na página 46.
- NISHIYAMA, M. et al. Facial deblur inference using subspace analysis for recognition of blurred faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 33, n. 4, p. 838–845, April 2011. Citado na página 18.
- ORTIZ, F.; TORRES, F. Automatic detection and elimination of specular reflectance in color images by means of ms diagram and vector connected filters. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, v. 36, n. 5, p. 681–687, Sept 2006. ISSN 1094-6977. Citado 3 vezes nas páginas 46, 47 e 48.
- PAN, J. et al. Blind image deblurring using dark channel prior. In: *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. Citado 12 vezes nas páginas 18, 19, 35, 45, 78, 80, 95, 97, 98, 99, 102 e 103.
- QUEIROZ, F.; REN, T. I. Automatic segmentation of specular reflections for endoscopic images based on sparse and low-rank decomposition. In: *Graphics, Patterns and Images (SIBGRAPI), 27th SIBGRAPI Conference on*. [S.l.: s.n.], 2014. p. 282–289. Citado 3 vezes nas páginas 22, 30 e 51.
- QUEIROZ, F. et al. Image deblurring using maps of highlights. In: *Acoustics, Speech and Signal Processing (ICASSP), IEEE International Conference on*. [S.l.: s.n.], 2013. p. 1608–1611. Citado 7 vezes nas páginas 22, 29, 35, 45, 46, 52 e 62.
- RAJAGOPALAN, A. N.; CHELLAPPA, R. *Motion Deblurring: Algorithms and Systems*. New York, NY, USA: Cambridge University Press, 2014. ISBN 1107044367, 9781107044364. Citado na página 33.
- ROTH, S.; BLACK, M. Fields of experts: a framework for learning image priors. In: *Computer Vision and Pattern Recognition. CVPR*. [S.l.: s.n.], 2005. v. 2, p. 860–867 vol. 2. Citado na página 41.
- SCHMIDT, U. et al. Discriminative non-blind deblurring. In: *2013 Conference on Computer Vision and Pattern Recognition (CVPR 2013)*. IEEE Computer Society, 2013. Disponível em: <<https://www.microsoft.com/en-us/research/publication/discriminative-non-blind-deblurring/>>. Citado na página 19.
- SHAN, Q.; JIA, J.; AGARWALA, A. High-quality motion deblurring from a single image. *ACM Trans. Graph.*, ACM, New York, NY, USA, v. 27, n. 3, p. 73:1–73:10, ago. 2008. Citado 9 vezes nas páginas 35, 40, 42, 43, 95, 97, 98, 99 e 103.
- SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). *Biometrika*, v. 52, n. 3/4, p. 591–611, Dec. 1965. Citado na página 87.

- SHEARER, P.; GILBERT, A. C.; III, A. O. H. Correcting camera shake by incremental sparse approximation. *CoRR*, abs/1302.0439, 2013. Citado 6 vezes nas páginas [35](#), [95](#), [97](#), [98](#), [99](#) e [103](#).
- SHEN, C.-T.; HWANG, W.-L.; PEI, S.-C. Spatially-varying out-of-focus image deblurring with l1-2 optimization and a guided blur map. In: *Acoustics, Speech and Signal Processing (ICASSP), IEEE International Conference on*. [S.l.: s.n.], 2012. p. 1069–1072. Citado 2 vezes nas páginas [35](#) e [36](#).
- SHEN, J.; CHAN, T. F. Mathematical models for local nontexture inpaintings. *SIAM Journal on Applied Mathematics*, v. 62, n. 3, p. 1019–1043, 2002. Citado na página [94](#).
- SHI, J.; XU, L.; JIA, J. Discriminative blur detection features. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2014. p. 2965–2972. ISSN 1063-6919. Citado na página [37](#).
- SHI, J.; XU, L.; JIA, J. Just noticeable defocus blur detection and estimation. In: *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2015. Citado 2 vezes nas páginas [35](#) e [36](#).
- SHI, J.; XU, L.; JIA, J. Just noticeable defocus blur detection and estimation. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2015. p. 657–665. ISSN 1063-6919. Citado na página [37](#).
- SIEGEL, R. L.; MILLER, K. D.; JEMAL, A. Cancer statistics, 2016. *CA: A Cancer Journal for Clinicians*, v. 66, n. 1, p. 7–30, 2016. Citado na página [102](#).
- SIMONCELLI, E. Bayesian denoising of visual images in the wavelet domain. In: MÜLLER, P.; VIDA KOVIC, B. (Ed.). *Bayesian Inference in Wavelet-Based Models*. [S.l.]: Springer New York, 1999, (Lecture Notes in Statistics, v. 141). p. 291–308. Citado na página [41](#).
- STEHLE, T. Removal of specular reflections in endoscopic images. *Acta Polytechnica*, v. 46, n. 4, 2006. Citado 2 vezes nas páginas [22](#) e [29](#).
- SUN, Z. et al. Removal of non-informative frames for wireless capsule endoscopy video segmentation. In: *2012 IEEE International Conference on Automation and Logistics*. [S.l.: s.n.], 2012. p. 294–299. Citado 2 vezes nas páginas [22](#) e [25](#).
- TAI, Y.-W.; BROWN, M. Single image defocus map estimation using local contrast prior. In: *Image Processing (ICIP), 2009 16th IEEE International Conference on*. [S.l.: s.n.], 2009. p. 1797–1800. Citado 2 vezes nas páginas [36](#) e [42](#).
- TAI, Y.-W. et al. Coded exposure imaging for projective motion deblurring. In: *IEEE Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on*. [S.l.], 2010. p. 2408–2415. Citado na página [37](#).
- TAJBAKSH, N.; GURUDU, S.; LIANG, J. A classification-enhanced vote accumulation scheme for detecting colonic polyps. In: YOSHIDA, H.; WARFIELD, S.; VANNIER, M. (Ed.). *Abdominal Imaging. Computation and Clinical Applications*. [S.l.]: Springer Berlin Heidelberg, 2013, (Lecture Notes in Computer Science, v. 8198). p. 53–62. Citado na página [104](#).

- TAJBAKHSI, N.; GURUDU, S. R.; LIANG, J. Automated polyp detection in colonoscopy videos using shape and context information. *IEEE Transactions on Medical Imaging*, v. 35, n. 2, p. 630–644, Feb 2016. ISSN 0278-0062. Citado na página 104.
- TCHOULACK, S.; LANGLOIS, J.; CHERIET, F. A video stream processor for real-time detection and correction of specular reflections in endoscopic images. In: *Circuits and Systems and TAISA Conference, 2008. NEWCAS-TAISA. Joint 6th International IEEE Northeast Workshop on*. [S.l.: s.n.], 2008. p. 49–52. Citado 2 vezes nas páginas 28 e 29.
- TZENG, J.; LIU, C.-C.; NGUYEN, T. Contourlet domain multiband deblurring based on color correlation for fluid lens cameras. *Image Processing, IEEE Transactions on*, v. 19, n. 10, p. 2659–2668, Oct 2010. Citado na página 18.
- VOGT, F. et al. *Making the Invisible Visible: Highlight Substitution by Color Light Fields*. 2002. Citado 4 vezes nas páginas 22, 25, 29 e 52.
- VOUGIOUKAS, K.; BOOM, B. J.; FISHER, R. B. Adaptive deblurring of surveillance video sequences that deteriorate over time. In: *2013 IEEE International Conference on Image Processing*. [S.l.: s.n.], 2013. p. 1085–1089. ISSN 1522-4880. Citado na página 18.
- WANG, J.; COHEN, M. F. Image and video matting: A survey. *Found. Trends. Comput. Graph. Vis.*, Now Publishers Inc., Hanover, MA, USA, v. 3, n. 2, p. 97–175, jan. 2007. Citado 2 vezes nas páginas 23 e 30.
- WANG, R.; TAO, D. Recent progress in image deblurring. *CoRR*, abs/1409.6838, 2014. Citado 3 vezes nas páginas 32, 34 e 41.
- WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. *Image Processing, IEEE Transactions on*, IEEE, v. 13, n. 4, p. 600–612, 2004. Citado 2 vezes nas páginas 91 e 96.
- WEISS, Y.; FREEMAN, W. What makes a good model of natural images? In: *Computer Vision and Pattern Recognition. CVPR. IEEE Conference on*. [S.l.: s.n.], 2007. p. 1–8. Citado na página 41.
- WHYTE, O.; SIVIC, J.; ZISSERMAN, A. Deblurring shaken and partially saturated images. In: *Computer Vision Workshops (ICCV Workshops), IEEE International Conference on*. [S.l.: s.n.], 2011. p. 745–752. Citado 4 vezes nas páginas 33, 34, 50 e 62.
- WHYTE, O. et al. Non-uniform deblurring for shaken images. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2010. Citado 2 vezes nas páginas 18 e 35.
- WHYTE, O. et al. Non-uniform deblurring for shaken images. *International Journal of Computer Vision*, v. 98, n. 2, p. 168–186, 2012. Citado 2 vezes nas páginas 33 e 34.
- WIPF, D. P.; ZHANG, H. Revisiting bayesian blind deconvolution. *CoRR*, abs/1305.2362, 2013. Citado 2 vezes nas páginas 18 e 45.
- WRIGHT, J. et al. Robust principal component analysis: Exact recovery of corrupted low-rank matrices via convex optimization. In: BENGIO, Y. et al. (Ed.). *Advances in Neural Information Processing Systems 22*. [S.l.]: Curran Associates, Inc., 2009. p. 2080–2088. Citado na página 55.

- WU, X. et al. Automatic hookworm detection in wireless capsule endoscopy images. *IEEE Transactions on Medical Imaging*, v. 35, n. 7, p. 1741–1752, July 2016. Citado na página 21.
- XU, L.; JIA, J. Two-phase kernel estimation for robust motion deblurring. In: DANILIDIS, K.; MARAGOS, P.; PARAGIOS, N. (Ed.). *ECCV (1)*. [S.l.]: Springer, 2010. (Lecture Notes in Computer Science, v. 6311), p. 157–170. ISBN 978-3-642-15548-2. Citado 14 vezes nas páginas 35, 40, 45, 46, 47, 48, 78, 81, 95, 97, 98, 99, 102 e 103.
- XU, L.; ZHENG, S.; JIA, J. Unnatural l0 sparse representation for natural image deblurring. In: *Computer Vision and Pattern Recognition (CVPR), IEEE Conference on*. [S.l.: s.n.], 2013. p. 1107–1114. Citado 3 vezes nas páginas 35, 40 e 81.
- XUELING, C.; YANNING, Z. Kernel refinement based on best light streak for motion deblurring. In: *International Conference on Orange Technologies*. [S.l.: s.n.], 2014. p. 17–20. Citado na página 79.
- YANG, J.; ZHANG, Y.; YIN, W. An efficient tvl1 algorithm for deblurring multichannel images corrupted by impulsive noise. *SIAM Journal on Scientific Computing*, SIAM, v. 31, n. 4, p. 2842–2865, 2009. Citado na página 46.
- YUAN, L. et al. Progressive inter-scale and intra-scale non-blind image deconvolution. *ACM Trans. Graph*, v. 27, n. 3, 2008. Citado na página 19.
- ZHOU, X. et al. Low-rank modeling and its applications in image analysis. *ACM Comput. Surv.*, ACM, New York, NY, USA, v. 47, n. 2, p. 36:1–36:33, dez. 2014. ISSN 0360-0300. Citado na página 52.