



UNIVERSIDADE
ESTADUAL DE LONDRINA

RICARDO PETRI SILVA

DETECTOR DE REFLEXOS LUMINOSOS COM LIMIAR
GLOBAL E AUMENTO DE CONTRASTE DE
LUMINÂNCIA EM IMAGENS

RICARDO PETRI SILVA

DETECTOR DE REFLEXOS LUMINOSOS COM LIMIAR
GLOBAL E AUMENTO DE CONTRASTE DE
LUMINÂNCIA EM IMAGENS

Dissertação apresentada ao Programa de Mestrado em Ciência da Computação da Universidade Estadual de Londrina para obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Alan Salvany Felinto.

Londrina
2018

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

Silva, Ricardo.

Detector de reflexos luminosos com Limiar Global e aumento de contraste de luminância em imagens / Ricardo Silva. - Londrina, 2018.
64 f. : il.

Orientador: Alan Felinto.

Dissertação (Mestrado em Ciência da Computação) - Universidade Estadual de Londrina, Centro de Ciências Exatas, Programa de Pós-Graduação em Ciência da Computação, 2018.

Inclui bibliografia.

1. Reflexos luminosos - Tese. 2. Detecção de reflexos - Tese. 3. Reflexos especulares - Tese. I. Felinto, Alan. II. Universidade Estadual de Londrina. Centro de Ciências Exatas. Programa de Pós-Graduação em Ciência da Computação. III. Título.

RICARDO PETRI SILVA

DETECTOR DE REFLEXOS LUMINOSOS COM LIMIAR GLOBAL
E AUMENTO DE CONTRASTE DE LUMINÂNCIA EM IMAGENS

Dissertação apresentada ao Programa de Mestrado em Ciência da Computação da Universidade Estadual de Londrina para obtenção do título de Mestre em Ciência da Computação.

BANCA EXAMINADORA

Orientador: Prof. Dr. Alan Salvany Felinto
Universidade Estadual de Londrina - UEL

Prof. Dr. José Alexandre de França
Universidade Estadual de Londrina - UEL

Prof. Dr. Sylvio Barbon Junior
Universidade Estadual de Londrina - UEL

Londrina, 06 de Abril de 2018.

*Tudo o que um sonho precisa para ser
realizado é alguém que acredite que ele
possa ser realizado. (Roberto Shinyashiki)*

AGRADECIMENTOS

A princípio gostaria de agradecer aos meus pais Sérgio Alves da Silva e Maria Elizete Petri Silva, por todo suporte e incentivo oferecido e, principalmente, por me ensinarem ser a pessoa que sou hoje. Devo à eles, sem dúvidas, todas conquistas adquiridas, pois possibilitaram que tudo isso se tornasse realidade. Também gostaria de agradecer ao meu irmão Lucas Petri Silva que também contribuiu e apoiou toda minha trajetória. Também gostaria de agradecer a minha namorada Erika Barbosa Vieira, por ser minha maior companheira e motivadora em todo esse processo, o seu suporte foi fundamental para que eu conseguisse atingir meus objetivos sem fraquejar.

Agradeço a todos que estiveram envolvidos nessa etapa da minha vida, desde os servidores da Universidade Estadual de Londrina até os professores que tive um maior contato. De modo especial gostaria de agradecer ao meu orientador Alan Salvany Felinto, que além de me aceitar como orientando, me incentivou e apoiou durante todo desenvolvimento do Programa de Mestrado, me passando confiança e instigando a realização de pesquisas e resoluções de problemas.

Por fim, gostaria de agradecer todas as amizades construídas durante toda essa jornada, desde a graduação no curso de Ciência da Computação até o momento atual. Essas amizades foram de extrema importância, especialmente aos amigos Saulo Martiello Mastelini, Gustavo Taiji Naozuka e Gabriel Marques Tavares, pois vivenciamos juntos tanto momentos de alegria quanto situações difíceis, mas sempre conseguimos passar por todos obstáculos.

*“Para ganhar conhecimento, adicione coisas
todos os dias. Para ganhar sabedoria,
elimine coisas todos os dias.”
(Lao-Tsé)*

SILVA, Ricardo Petri. **Detector de reflexos luminosos com Limiar Global e aumento de contraste de luminância em imagens**. 2018. 64 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Estadual de Londrina, Londrina, 2018.

RESUMO

A presença de reflexos luminosos (RL) em imagens digitais podem interferir na coloração dos pixels das regiões afetadas. Estes pixels tendem a ter seu canal de cor saturado e, dessa forma, apresentam aparência esbranquiçada e conseqüentemente, perda de sua coloração. Processos de decisões que utilizam imagens digitais podem ser prejudicados pela incidência de RL. Alguns exemplos de problemas causados pela presença de RL são cirurgias assistidas por câmeras em tempo real, reconhecimento facial e ocular. Este trabalho propõe um algoritmo chamado Aumento de Contraste de Potenciais Regiões de Reflexos Luminosos, que consiste em um pré-processamento para aumentar o contraste de potenciais regiões que possuem RL com o objetivo de melhorar o desempenho de detectores automáticos de RL. Além disso, quatro detectores automáticos de RL foram comparados com e sem a utilização do algoritmo de pré-processamento. O primeiro é uma técnica já consolidada na literatura chamada de Limiar Chang-Tseng (CT). Três novos detectores automáticos de RL são propostos. O Limiar Chang-Tseng adaptado, Pico de Histograma Adaptado e Limiar Global. Foram empregados quatro métricas de performance para avaliar estes detectores, nomeados como, Acurácia, Precisão, Exatidão e Raiz do Erro Quadrático Médio (RMSE em Inglês). A métrica de Exatidão é uma novidade proposta por este trabalho. Para um parâmetro de avaliação destas métricas, um modelo de referência definido manualmente foi criado. O detector Limiar Global combinado com o algoritmo de pré-processamento apresentou os melhores resultados comparado aos demais detectores avaliados, com uma taxa média de Exatidão de 82.47%.

Palavras-chave: Reflexos luminosos. Detecção reflexos. Reflexos especulares.

SILVA, Ricardo Petri. **Automatic luminous reflection detector using global threshold with increased luminance contrast in images**. 2018. 64 p. Dissertation (Master's Degree in Science in Computer Science) – Universidade Estadual de Londrina, Londrina, 2018.

ABSTRACT

The incidence of Luminous Reflections (LR) on captured images can interfere in the pixels coloration of the affected regions. These pixels tend to oversaturate, becoming whitish and, consequently, loss of original color. Decision processes which employ digital images can be impaired by the incidence of LR. Some examples of problems caused by the presence of RL are real-time surgeries assisted by cameras, facial and ocular recognition, etc. This work proposes an algorithm called Contrast Enhancement of Potential LR Regions which is a pre-processing method to increase the contrast of potential LR regions, to improve the performance of automatic LR detectors. In addition, four automatic LR detectors were compared with and without the employment of the pre-processing algorithm. The first one is a technique already consolidated in the literature called the Chang-Tseng Threshold. Three novel automatic LR detectors are proposed. The Adapted Chang-Tseng Threshold, Adapted Histogram Peak and Global Threshold. Were employed four performance metric to evaluate the detectors, namely, Accuracy, Precision, Exactitude, and RMSE (Root Mean Square Error). The Exactitude metric is a novel developed by this work. For an evaluation parameter of these metrics, a manually defined reference model was created. The Global Threshold detector combined with the pre-processing algorithm presented the best results among all detectors evaluated, with an average Exactitude rate of 82.47%.

Keywords: Luminous reflection. Reflection detection. Specular reflection.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de saturação do pixel devido à alta intensidade de luminosidade.	18
Figura 2 – Variação de tons de cinza da cor preta ao branco.	19
Figura 3 – Exemplo de histograma de uma imagem em níveis de cinza.	20
Figura 4 – Exemplo de restauração de uma imagem com reflexo luminoso utilizando a técnica de inpainting.	21
Figura 5 – Processos executados para detecção de RL.	25
Figura 6 – Exemplo de Detecção Manual de RL.	26
Figura 7 – Sequência de imagens utilizadas para experimento do primeiro grupo de imagens.	33
Figura 8 – Sequência de imagens utilizadas para experimento do segundo grupo de imagens.	34
Figura 9 – Sequência de imagens utilizadas para experimento do terceiro grupo de imagens.	35
Figura 10 – Sequência de imagens utilizadas para experimento do quarto grupo de imagens.	35
Figura 11 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no primeiro grupo de imagens.	42
Figura 12 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no segundo grupo de imagens.	42
Figura 13 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no terceiro grupo de imagens.	43
Figura 14 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no quarto grupo de imagens.	43
Figura 15 – Gráfico de barras da métrica da média final de Acurácia de cada um dos detectores automáticos.	44
Figura 16 – Gráfico de barras da métrica da média final de Precisão de cada um dos detectores automáticos.	44
Figura 17 – Gráfico de barras da métrica da média final de Exatidão de cada um dos detectores automáticos.	45
Figura 18 – Gráfico de barras da métrica da média final de RMSE de cada um dos detectores automáticos.	45
Figura 19 – Sequência de resultados obtidos utilizando imagem da Caneca original, detector manual, detector por LR e detector por LGCPP respectivamente.	47
Figura 20 – Sequência de resultados obtidos utilizando imagem do Bule original, detector manual, detector por LR e detector por LGCPP respectivamente.	48

Figura 21 – Sequência de resultados obtidos utilizando imagem do Pote original, detector manual, detector por LR e detector por LGCPP respectivamente.	49
Figura 22 – Sequência de resultados obtidos utilizando a Imagem Sintética original, detector manual, detector por LR e detector por LGCPP respectivamente.	50
Figura 23 – Sequência de resultados obtidos utilizando imagem do Cilindro metálico original, detector manual, detector por LR e detector por LGCPP respectivamente.	51
Figura 24 – Sequência de resultados obtidos utilizando imagem do Peito de frango original, detector manual, detector por LR e detector por LGCPP respectivamente.	51
Figura 25 – Sequência de resultados obtidos utilizando imagem da Face 1 original, detector manual, detector por LR e detector por LGCPP respectivamente.	52
Figura 26 – Sequência de resultados obtidos utilizando imagem da Face 2 original, detector manual, detector por LR e detector por LGCPP respectivamente.	52
Figura 27 – Sequência de resultados obtidos utilizando imagem da Face 3 original, detector manual, detector por LR e detector por LGCPP respectivamente.	52
Figura 28 – Sequência de resultados obtidos utilizando imagem da Face 4 original, detector manual, detector por LR e detector por LGCPP respectivamente.	53
Figura 29 – Sequência de resultados obtidos utilizando imagem da Face 5 original, detector manual, detector por LR e detector por LGCPP respectivamente.	53
Figura 30 – Sequência de resultados obtidos utilizando imagem da Face 6 original, detector manual, detector por LR e detector por LGCPP respectivamente.	53
Figura 31 – Sequência de resultados obtidos utilizando imagem da Face 7 original, detector manual, detector por LR e detector por LGCPP respectivamente.	54
Figura 32 – Sequência de resultados obtidos utilizando imagem do Couro Vermelho original, detector manual, detector por LR e detector por LGCPP respectivamente.	54
Figura 33 – Sequência de resultados obtidos utilizando imagem do Couro marrom original, detector manual, detector por LR e detector por LGCPP respectivamente.	55
Figura 34 – Sequência de resultados obtidos utilizando imagem do Vidro 1 original, detector manual, detector por LR e detector por LGCPP respectivamente.	55
Figura 35 – Sequência de resultados obtidos utilizando imagem do Vidro 2 original, detector manual, detector por LR e detector por LGCPP respectivamente.	56
Figura 36 – Sequência de resultados obtidos utilizando imagem do Metal original, detector manual, detector por LR e detector por LGCPP respectivamente.	56
Figura 37 – Sequência de resultados obtidos utilizando imagem do Tecido original, detector manual, detector por LR e detector por LGCPP respectivamente.	57

Figura 38 – Sequência de resultados obtidos utilizando imagem do Plástico original, detector manual, detector por LR e detector por LGCPP respectivamente.	57
Figura 39 – Sequência de resultados obtidos utilizando da imagem Duodenite original, detector manual, detector por LR e detector por LGCPP respectivamente.	58
Figura 40 – Sequência de resultados obtidos utilizando da imagem Varizes gástricas original, detector manual, detector por LR e detector por LGCPP respectivamente.	59
Figura 41 – Sequência de resultados obtidos utilizando da imagem Duodenite original, detector manual, detector por LR e detector por LGCPP respectivamente.	60

LISTA DE TABELAS

Tabela 1 – Resultados obtidos pelos detectores automáticos de RL do primeiro e segundo grupo de imagens.	40
Tabela 2 – Resultados obtidos pelos detectores automáticos de RL do segundo, terceiro e quarto grupo de imagens.	41

LISTA DE ABREVIATURAS E SIGLAS

MaxIP	Maior intensidade do pixel.
MinIP	Menor intensidade do pixel.
VP	Verdadeiro positivo.
VN	Verdadeiro negativo.
FP	Falso positivo.
FN	Falso negativo.
CT	Chang e Tseng.
LR	Limiar de Referência.
LG	Limiar Global.
LCT	Limiar CT.
LCTA	Limiar CT Adaptado.
PHA	Pico do Histograma Adaptado.
SPP	Sem pré-processamento.
CPP	Com pré-processamento.

SUMÁRIO

1	INTRODUÇÃO	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Reflexos Luminosos em Imagens	17
2.2	Informações Heurísticas e Estatísticas de Imagens	17
2.3	Imagens em Níveis de Cinza	18
2.4	Histograma	19
2.5	Detecção de Reflexos Luminosos	20
2.5.1	Detector por Limiar Chang-Tseng	20
2.6	Restauração de Regiões que Possuem Reflexos Luminosos	21
2.6.1	<i>Inpainting</i>	21
3	TRABALHOS RELACIONADOS	23
4	METODOLOGIA PROPOSTA	25
4.1	Detecção Manual de RL	25
4.2	Aumento de Contraste de Potenciais Regiões de RL	26
4.3	Detectores Automáticos de RL	28
4.3.1	Detector por Limiar CT Adaptado	28
4.3.2	Pico do Histograma Adaptado	29
4.3.3	Limiar Global	30
5	AVALIAÇÃO DOS EXPERIMENTOS	32
5.1	Aquisição de Imagens	32
5.2	Métricas de avaliação	33
5.2.1	Detector por Limiar de Referência	37
6	RESULTADOS E DISCUSSÕES	38
6.1	Limitações do trabalho	46
7	CONCLUSÃO	61
	REFERÊNCIAS	62
	Trabalhos Publicados pelo Autor	64

1 INTRODUÇÃO

A presença de reflexos luminosos (RL) em imagens é um problema recorrente em diversas áreas, especialmente para aplicações em tempo real, como em vídeos de cirurgias [1, 2]. Nestes casos, os RL prejudicam decisões feitas por um cirurgião, visto que as regiões afetadas apresentam alto nível de intensidade de luminosidade, dificultando seus diagnósticos. Reconhecimento facial e ocular são outros exemplos em que os RL podem interferir em processos de decisões, visto que a presença dos RL alteram as informações originais dos pixels [3]. Esta alteração é causada devido a alta intensidade de luminosidade que o pixel adquire. Dessa forma sua informação original é modificada e processos de decisões são prejudicados por esta alteração. Os casos mencionados enfatizam a relevância de corrigir automaticamente a presença de RL em diferentes tipos de imagens.

Este trabalho tem como objetivo a detecção automática de RL. Para isso são propostos quatro detectores automáticos de RL. O primeiro detector é o Limiar Chang-Tseng, já consolidado na literatura [4]. Os demais detectores são o Limiar Chang-Tseng Adaptado, Pico de Histograma Adaptado e Limiar Global, que consistem em novas propostas deste trabalho. O Limiar Chang-Tseng Adaptado e o Pico de Histograma Adaptado são expansões de suas técnicas originais, visto que foram primeiramente propostas em aplicações específicas. A adaptação tem como objetivo tornar a técnica aplicável em diversos cenários. Por fim, a técnica de Limiar Global é uma nova proposta por este trabalho, criada com a capacidade de detectar RL em diversas aplicações.

Neste trabalho, também existe uma hipótese para melhorar o desempenho dos detectores automáticos por meio de um algoritmo de pré-processamento. Este pré-processamento é chamado de Aumento de Contraste de Potenciais Regiões de RL e tem como objetivo aumentar o contraste de luminosidade entre pixels normais e RL. Os aumentos nas intensidades dos pixels são feitos apenas nas potenciais regiões de RL, com o objetivo de melhorar a performance dos detectores automáticos de RL. Os resultados obtidos com e sem a aplicação do pré-processamento nos detectores automáticos de RL foram comparados para verificar sua performance em diversos cenários.

Os RL foram detectados nas imagens com os quatro detectores apresentados com o auxílio do método de pré-processamento. As detecções dos pixels com alta intensidade de luminosidade foram feitas após a transformação das imagens para níveis de cinza, uma vez que esta representação apresenta apenas informações sobre o valor de intensidade dos pixels. Além disso, foram utilizadas um total de 23 imagens para experimentação aplicando os quatro detectores automáticos definidos anteriormente. Todas estas imagens apresentam incidência de RL espalhados pela imagem, cenários, texturas e complexidades diferentes.

Os resultados dos detectores automáticos de RL foram comparados com um modelo de referência definido manualmente. Esta detecção manual foi feita utilizando um editor de imagens, onde cada pixel foi marcado como normal ou como RL. Além dos detectores automáticos de RL, também foi criado um detector que utiliza informações da detecção manual. Este detector é chamado de Limiar de Referência e serve de modelo para comparar a performance dos demais detectores.

As métricas utilizadas neste trabalho foram Acurácia, Precisão, Exatidão e RMSE (*Root Mean Square Error*). Estas métricas de avaliação fornecem informações sobre o desempenho dos detectores automáticos de RL. A utilização do pré-processamento antes de aplicar os detectores apresentaram resultados satisfatórios, sendo que a combinação do detector Limiar Global com pré-processamento obteve melhores resultados na maioria dos casos testados.

A seguir serão apresentadas as demais seções deste trabalho. A Seção 2 apresenta a fundamentação teórica, que expõe informações necessárias para entendimento do desenvolvimento deste trabalho. A Seção 3 aborda os trabalhos relacionados. A Seção 4 apresenta a metodologia adotada para detecção de RL utilizando o pré-processamento proposto. A Seção 5 exibe a avaliação dos experimentos, que consiste nas imagens utilizadas para experimentação e definição das métricas de avaliação de performance. Na Seção 6 são mostrados os resultados quantitativos obtidos por meio de tabelas. Estas tabelas comparam o desempenho dos Detectores Automáticos de RL em relação as imagens submetidas ao pré-processamento e imagens sem pré-processamento. Também é abordado nesta seção resultados qualitativos por meio de comparações visuais das imagens submetidas à detecção. Por fim, na seção 7 é exibida a conclusão desta dissertação de mestrado, ressaltando as informações adquiridas com o desenvolvimento deste trabalho e também são apresentados os trabalhos a serem feitos futuramente.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção são abordadas informações necessárias para entendimento de todo processo de desenvolvimento do trabalho e também alguns conceitos que estão diretamente ligados aos artefatos de RL. Primeiramente será apresentado informações de RL e como identificá-los, bem como técnicas para restauração de regiões afetadas por estes artefatos luminosos. Além disso, serão explicados alguns conceitos adicionais para possibilitar a criação das adaptações sugeridas nos detectores automáticos de RL e também dos limiares para distinguir RL de pixels normais.

2.1 Reflexos Luminosos em Imagens

A incidência de RL em imagens, também conhecida como reflexo especular, causa alteração na representação de cor. Em alguns casos, a intensidade de luminosidade é alta o suficiente para causar saturação dos pixels. Estes fatores de RL nas imagens é um problema a ser resolvido [5]. Algumas tarefas podem ser prejudicadas quando um processo de análise é necessário, como por exemplo, diagnósticos médicos em cirurgias [6]. Dessa forma, a detecção de RL em imagens pode evitar erros de decisões significantes em diversas aplicações. Um exemplo destas aplicações são cirurgias toracoscópicas [7], onde o aspecto pálido e úmido do tecido interno do corpo humano produz regiões de RL quando absorvido pelo sensor da câmera que realiza a transmissão de vídeo em tempo real, o que dificulta um diagnóstico, até mesmo por um cirurgião especialista.

A Figura 1 apresenta uma caneca com exemplo de saturação causada pela alta intensidade de luminosidade. Neste exemplo, de acordo com a região delimitada pelo círculo vermelho, alguns pixels originalmente verdes adquirem colorações próximas ao branco devido ao RL.

2.2 Informações Heurísticas e Estatísticas de Imagens

Os limiares utilizados neste trabalho foram obtidos a partir de estatísticas de imagens e informações heurísticas. As estatísticas de imagens consistem de informações como: pixel de maior intensidade da imagem, pixel de menor intensidade da imagem, média dos valores dos pixels da imagem, desvio padrão dos pixels da imagem, entre outras variações.

Considerando que os RL possuem altas intensidades de luminosidades, é possível manipular estatísticas de imagens para identificá-los. Entretanto, a utilização unicamente de estatísticas podem ser insuficientes para detectar a totalidade ou maior parte de RL



Figura 1 – Exemplo de saturação do pixel devido à alta intensidade de luminosidade.

em uma imagem. Dessa forma, foi combinada a utilização de estatísticas de imagens com informações heurísticas, com o objetivo de tornar o processo de detecção mais ágil e preciso. Exemplos desta combinação serão demonstradas na seção 4, principalmente na obtenção dos limiares propostos.

2.3 Imagens em Níveis de Cinza

Como pode ser visto na seção 3 de Trabalhos Relacionados, o trabalho de Vazquez et al. [8] descreve a importância em separar as informações de cromaticidade, da luminância de uma imagem, antes da identificação dos pixels que possuem RL. De acordo com esta informação, optou-se neste trabalho a utilização de níveis de cinza para identificação dos artefatos luminosos nas imagens.

A imagem em nível de cinza apresenta o valor de cada pixel como uma amostra única, ou seja, traz apenas informações sobre sua intensidade. Imagens desse tipo são compostas exclusivamente por tons de cinza, variando da cor preta à cor branca [9]. As imagens em níveis de cinza são muitas vezes o resultado da medição da intensidade de luminância em cada pixel em uma única faixa do espectro eletromagnético (por exemplo, infravermelho, luz visível, ultravioleta, etc.)

A Figura 2 demonstra todas as intensidades que um pixel pode assumir em níveis de cinza. A variação dos valores de intensidade vão de 0 à 255, sendo que o valor 0 representa a intensidade mais forte da cor preta e o valor 255 representa a intensidade mais forte da cor branca. Os valores intermediários de 0 à 255 sofrem variações em nível de cinza partindo da cor preta até atingir a cor branca [10]. Dessa forma, por poder realizar manipulações diretamente sobre as intensidades de luminância de uma imagem, esta representação foi empregada para a realização da identificação dos RL, baseados em sua intensidade, que normalmente terão intensidades altas, com colorações semelhantes




Figura 2 – Variação de tons de cinza da cor preta ao branco.

ao branco.

2.4 Histograma

O histograma é a representação de distribuição de frequência de um determinado tipo de dado [11]. A frequência de cada valor é representado por uma barra. Cada barra de um histograma representa um valor diferente e se localiza no eixo X do gráfico cartesiano. No eixo Y, são representadas as frequências de cada valor. De acordo com esta definição, as intensidades dos pixels de imagens digitais representam os valores e a repetição desses valores representam as frequências.

Considerando uma imagem em níveis de cinza, as variações de intensidade de 0, tom mais próximo de preto, à 255, tom mais próximo de branco, são possíveis. A Figura 3 apresenta um exemplo de variação de intensidades em níveis de cinza de uma imagem por meio de um histograma. Neste histograma, é possível identificar a frequência referente a cada intensidade presente na imagem.

A análise de um histograma pode oferecer informações valiosas sobre a disposição dos dados avaliados. Neste trabalho, a sua utilização consiste na identificação de pixels com alta intensidade, que caracterizam os RL e normalmente se encontram na extremidade da direita do histograma, devido as suas altas intensidade de luminosidade.

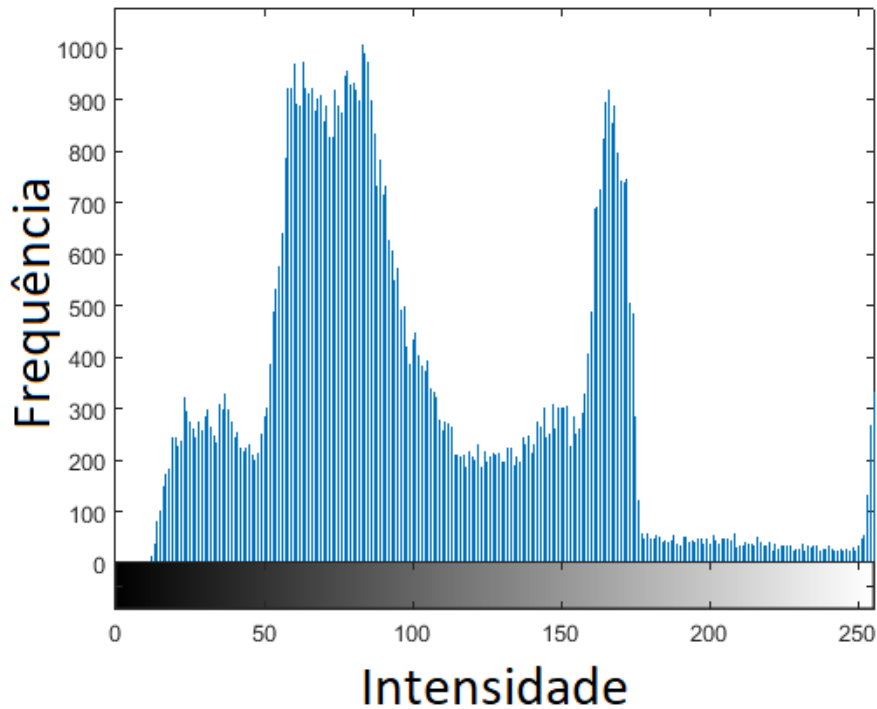


Figura 3 – Exemplo de histograma de uma imagem em níveis de cinza.

2.5 Detecção de Reflexos Luminosos

Muitas técnicas utilizam informações de intensidade de luminosidade dos pixels para detecção de RL, assim como proposto pelo trabalho de Chang e Tseng [4]. Para simplificar, nas demais seções, a intensidade máxima e mínima dos pixels de uma imagem são referenciados como MaxIP e MinIP, respectivamente.

2.5.1 Detector por Limiar Chang-Tseng

Este detector de RL foi escolhido na literatura para ser um dos detectores automáticos utilizados neste trabalho. O Limiar Chang-Tseng (CT) [4] é calculado aplicando um fator fixo que multiplica a diferença entre o MaxIP e MinIP da imagem. Esta técnica foi inicialmente proposta para detectar RL em faces humanas. O limiar CT é dado por:

$$\text{Limiar CT} \leftarrow 0.8 \cdot (\text{MaxIP} - \text{MinIP}). \quad (2.1)$$

Os pixels com intensidades maiores que o Limiar CT serão classificados como RL, enquanto os pixels restantes serão considerados como pixels normais. Neste trabalho, a técnica de Limiar CT foi comparada com os demais detectores automáticos propostos, que consistem no Limiar CT Adaptado, Pico de Histograma Adaptado e Limiar Global e

serão demonstrados na próxima seção. Todos estes detectores são avaliados em diferentes tipos de imagens, que também incluem incidências de RL em faces humanas.

2.6 Restauração de Regiões que Possuem Reflexos Luminosos

A partir do momento em que determinadas regiões de RL são identificadas em uma imagem, é possível aplicar alguma técnica de restauração. Esta técnica de restauração fará com que os artefatos de luminosidade sejam substituídos por pixels iguais ou semelhantes aos pixels originais da imagem, antes da incidência dos RL. Essa substituição de informações pode ser feita por técnicas citadas na literatura, como por exemplo, a técnica de *inpainting*.

2.6.1 *Inpainting*

A técnica de *inpainting* consiste no preenchimento de uma região com informações de sua fronteira [12]. Para imagens que apresentam RL, a técnica de *inpainting* preencheria as regiões afetadas por RL utilizando informações dos pixels da fronteira. Estes pixels da fronteira são pixels normais, sem a presença de RL.

Na Figura 4 é apresentado um exemplo de restauração de uma região que sofreu ação de RL utilizando a técnica de *inpainting*. Essas imagens foram obtidas do trabalho de Pingtan et al. [13]. Nesta imagem, é possível verificar em sua região central, onde se encontravam os focos de RL, a restauração dos pixels pelo preenchimento de pixels das fronteiras dos RL.



(a) Imagem original



(b) Imagem após aplicação da técnica de inpainting

Figura 4 – Exemplo de restauração de uma imagem com reflexo luminoso utilizando a técnica de inpainting.

O processo de preenchimento por informações da fronteira dos RL pode ser feito

de diversas maneiras [14]. Algumas das possíveis formas poderia ser realizada com a interpolação dos pixels da fronteira ou no preenchimento por vizinhança pelos pixels da fronteira.

A interpolação dos pixels da fronteira poderia ser feita da seguinte forma: primeiramente seriam identificadas todas as regiões a serem preenchidas. Em sequência, seria definido a forma de agrupamento dos pixels de cada limite dessa região. Uma forma de se realizar essa tarefa para regiões praticamente homogêneas seria a varredura da imagem no sentido horizontal da esquerda para à direita. Após a identificação de uma região de RL, os pixels das duas extremidades seriam obtidas e interpolados. Assim, toda a linha horizontal dessa localidade será preenchida pelo valor obtido na interpolação, desde a extremidade inicial até a extremidade final. Esse processo se repetiria até que a varredura chegasse ao fim da imagem. Já o preenchimento por vizinhança seria feito atribuindo as informações de cada pixel da fronteira à região de RL, até que toda essa região seja preenchida.

3 TRABALHOS RELACIONADOS

Nos últimos anos, diferentes técnicas para detecção de RL foram propostas com aplicações diversas. Saint-Pierre et al. [7] propõe um detector de reflexos luminosos baseado no último pico do histograma nos três canais RGB (*Red*, *Green*, *Blue*) e isolam os pixels encontrados neste pico. A técnica possui quatro passos: aumento de intensidade dos RL que correspondem aos pixels saturados, remoção de ruídos para evitar pequenas variações no histograma, localização do último pico do histograma em cada um dos canais RGB e isolamento destes pixels. Entretanto, esta técnica foi elaborada para detecção de RL em imagens de cirurgias toracoscópicas, que contém cenários similares, sem avaliações em imagens com diferentes características.

O trabalho de Vazquez et al. [8] traz informações para executar a identificação de RL em uma imagem. De acordo com os autores é necessário separar as informações de cor e luminosidade da imagem. Os RL na imagem são caracterizados pela alta intensidade de luminosidade dos pixels, o que resulta na saturação dos canais de cor. Isto causa perda de informação de cor do pixel e, dessa forma, os pixels tendem a adquirir coloração próxima ao branco.

Tchoulack, Langlois e Cheriet [1] propõem a detecção de reflexos luminosos baseada na decomposição de histograma. As imagens utilizadas para análise foram obtidas de procedimentos de endoscopia. Nestas imagens, de acordo com os autores, os pixels vermelhos são dominantes e os brancos representam os RL. Dessa forma, a combinação da intensidade exibida pelo histograma nos canais RGB possui o potencial de localizar os RL da imagem. Também é evidenciado que a utilização de níveis de cinza é adequado para detecções de RL, uma vez que esta representação apresenta informações de intensidade de luminosidade isoladamente da coloração da imagem.

Guo et al. [15] propõe um método de limiarização para detecção de RL. Depois da fase de detecção de RL, um processo de supressão é iniciado, com objetivo de restaurar a imagem afetada pelos RL. Porém, o trabalho não esclarece como o limiar para distinguir pixels normais de RL é obtido e a técnica foi avaliada apenas em cenários similares de imagens de endoscopia.

Karapetyan e Sarukhanyan [6] propõem uma janela deslizante combinada com um histograma local para identificação de RL. Esta janela possui um tamanho pré-definido com um histograma da imagem no canal Y do espaço de cor YUV, onde o canal Y representa a luminância dos pixels e os canais UV descrevem a crominância. Estas informações são analisadas para realizar um limiar adaptativo que é calculado para cada movimento da janela na imagem. Este trabalho também apresenta uma restauração das regiões afetadas

pelos RL utilizando a técnica de inpainting. Apesar de apresentar resultados satisfatórios, apenas imagens de procedimentos de endoscopia foram avaliadas.

Chang e Tseng [4] apresentam uma técnica de limiarização para detecção de RL em fotografias de faces humanas. O valor de limiar proposto pelos autores é calculado pela subtração do pixel de maior intensidade pelo pixel de menor intensidade da imagem e o valor resultante é multiplicado por um fator fixo de 0,8. Todavia, a utilização de um fator fixo para detectar RL em diferentes imagens pode trazer resultados negativos, sendo que um detector automático que se adapta a diferentes cenários se mostra mais promissor. Esta técnica foi implementada neste trabalho com o objetivo de compará-la com os outros detectores propostos.

Os trabalhos relacionados selecionados nesta dissertação demonstram diferentes técnicas para detecção de RL em imagens. Neste trabalho, foram utilizadas fundamentações teóricas dos trabalhos citados acima para propor um novo detector automático de RL. Este novo detector, chamado de Limiar Global, tem como objetivo detectar RL em diversos cenários, visto que a maioria das aplicações relatadas são destinadas para cenários específicos, como por exemplo, imagens de procedimentos cirúrgicos [7, 15, 1]. Para a identificação de intensidades de luminosidades nas imagens é utilizado níveis de cinza, uma vez que esta representação apresenta apenas informações sobre a intensidade do pixel e não depende da coloração da imagem.

4 METODOLOGIA PROPOSTA

Neste trabalho, os pixels de alta intensidade de luminosidade, e que possivelmente seriam RL, são detectados utilizando a representação em níveis de cinza. Além disso, o pré-processamento proposto (Aumento de Contraste de Potenciais Regiões de RL) é utilizado para melhorar a performance dos detectores automáticos de RL. A Figura 5 demonstra cada passo para a realização da detecção dos RL, desde a detecção manual até a aplicação dos detectores automáticos.

De acordo com a Figura 5, uma amostra de imagem é submetida à detecção manual de RL, conforme o passo (1). Esta mesma imagem é conduzida ao passo (2). Este passo consiste na aplicação do pré-processamento. A caixa pontilhada do passo (2) denota a utilização ou não do pré-processamento, uma vez que os resultados das imagens com e sem pré-processamento são comparadas. O passo (3) demonstra a aplicação dos detectores automáticos de RL na imagem atual. Por fim, são feitas as Análises de Performance das saídas geradas pelos detectores automáticos de RL com a saída gerada pela Detecção Manual de RL.

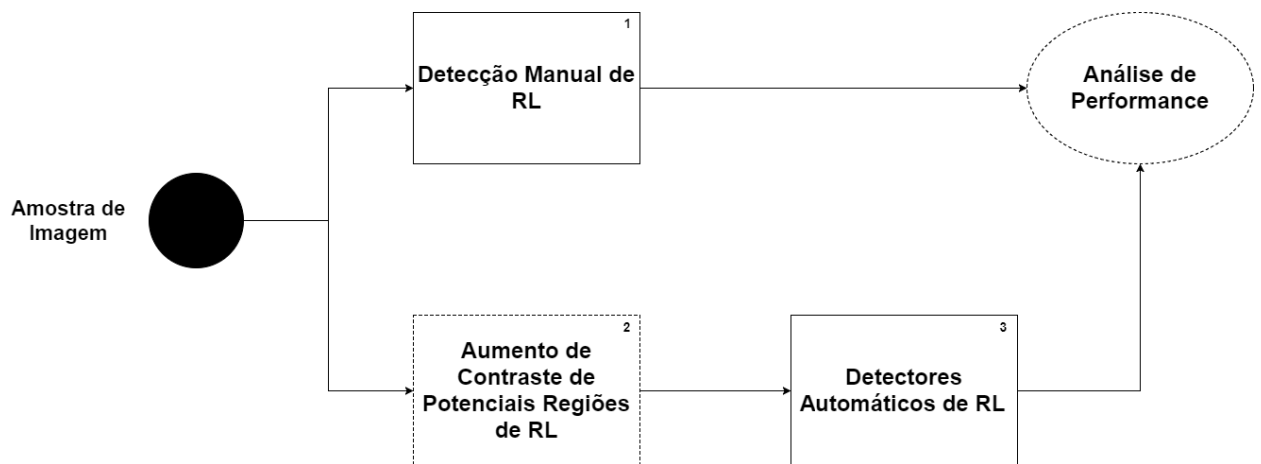


Figura 5 – Processos executados para detecção de RL.

4.1 Detecção Manual de RL

Foi construído um modelo de referência manual para avaliar a performance dos detectores automáticos de RL. Este modelo de referência, chamado de Detecção Manual de RL, foi projetado para classificar os pixels da imagem como normais ou RL. Considerando que o modelo de referência foi feito por humanos, o mesmo está sujeito a erros. Com o objetivo de minimizar estes erros de classificações, cinco voluntários foram designados

para realizar a detecção manual. O comportamento de RL em uma imagem foi passado para estes voluntários, como definido na seção 2.1.

Depois deste processo, os voluntários utilizaram um editor de imagens para classificar os pixels da imagem que possuíam comportamentos de RL. Posteriormente, as imagens avaliadas foram ampliadas para melhor visualização. Os pixels que visualmente apresentavam tendências de serem normais não sofreram modificações, enquanto os pixels que apresentavam tendências de RL foram marcados. Após todas marcações feitas pelos voluntários, uma nova imagem binarizada foi criada. Os pixels pretos desta nova imagem representam os pixels normais e os pixels brancos representam os RL marcados pelos voluntários.

Para finalizar o processo de detecção manual de RL, um esquema de votação por maioria entre todas as marcações foi aplicada, para decidir quando um pixel foi classificado como RL ou não de acordo com a detecção manual de RL. Esta contagem é feita referente a marcação de cada pixel da imagem. Se um determinado pixel foi considerado como RL em pelo menos três das cinco marcações, o mesmo será considerado como RL. Na Figura 6, um exemplo de detecção manual de RL é mostrado em uma imagem de peito de frango. Nesta figura, os pixels com coloração preta representam os pixels normais e os pixels com coloração branca representam os RL.




Figura 6 – Exemplo de Detecção Manual de RL.

4.2 Aumento de Contraste de Potenciais Regiões de RL

A seguir serão demonstradas algumas abordagens para realizar o aumento de contraste entre pixels normais e RL em imagens. Os resultados negativos destas abordagens motivaram o desenvolvimento de uma nova técnica mais adequada para o problema tratado. Primeiramente, foram avaliados o aumento das intensidades dos pixels de forma igualitária por um fator constante, com objetivo de destacar os RL. Entretanto, os resultados não foram satisfatórios, tendo em vista que todos pixels foram tratados da mesma forma e o contraste entre os pixels que possuíam RL e pixels normais não sofreram mudanças significativas.

Também foi verificado se a equalização de histograma poderia melhorar a distribuição de luminosidade pela cena. Porém, os focos de luminosidade permaneceram nas mesmas regiões da imagem e a distinção de RL de pixels normais ainda se mostrava uma tarefa difícil.

A utilização de janelas de realce local também foi verificada como uma proposta encontrada na literatura [16], onde pequenas janelas são avaliadas na imagem. Estas janelas tem como objetivo destacar os pixels centrais, aumentando o contraste de pixels com alta intensidade de luminosidade. Esta técnica obteve resultados mais promissores comparado as outras técnicas mencionadas, visto que houve aumento de contraste entre pixels normais e RL. Todavia, os resultados não eram bons o suficiente, visto que os resultados adquiridos pela técnica atual atingem melhores resultados e, dessa forma, esta técnica foi ultrapassada pelo método adotado neste trabalho para realização de aumento de contraste.

Este método adotado é chamado de Aumento de Contraste de Potenciais Regiões de RL e tem como objetivo, como o próprio nome sugere, aumentar o contraste de potenciais regiões que possuem RL de pixels normais, para melhorar a performance de detectores automáticos de RL. Primeiramente, as potenciais regiões de RL são identificadas a partir de um método de limiarização. Este método de limiarização consiste em definir um valor que servirá de fronteira entre um pixel normal e um reflexo luminoso. Sua operação é baseada na avaliação da intensidade de luminosidade dos pixels [16].

Para definir o limiar utilizado neste processo e também nos demais detectores automáticos de RL que serão demonstrados, foram utilizadas estatísticas de imagens e informações heurísticas. A média dos valores dos pixels de cada imagem em níveis de cinza foi utilizada neste pré-processamento, visto que pixels que possuem RL apresentam valores de intensidade altos, representados por colorações próximas do branco puro, portanto, provavelmente valores maiores que a média dos valores dos pixels. Porém, para minimizar o erro em classificar pixels normais como RL, foi adicionado o valor de desvio padrão da imagem ao valor anteriormente obtido. Dessa forma, um limiar mais preciso e adaptativo é obtido. Este limiar é representado pelo símbolo ω e é dado por:

$$\omega \leftarrow \theta + \sigma \quad \theta = \begin{cases} \frac{\text{MaxIP}}{2} & \text{se } \mu < \frac{\text{MaxIP}}{2} \\ \mu & \text{caso contrário,} \end{cases} \quad (4.1)$$

onde μ representa o valor médio de intensidade dos pixels e σ representa o valor de desvio padrão da imagem. Foi adicionada uma condicional para valores médios de intensidades baixos para melhorar o limiar final, e dessa forma, minimizar erros de classificações de pixels normais como RL.

Quando verificado que um pixel possui intensidade maior que o ω , outro processo é

iniciado para aumentar sua intensidade. O aumento de intensidade segue a seguinte regra: A MaxIP da imagem será subtraída do pixel atual e dividido por 3, e o valor resultante será adicionado ao pixel atual. A divisão por 3 é necessária para evitar que os pixels obtenham o mesmo valor de MaxIP e também um aumento de intensidade sem controle, visto que este aumento pode interferir no valor final de MaxIP. Este aumento de contraste tem como objetivo identificar potenciais RL que não seriam detectados pelos detectores automáticos. Este processo é feito para cada pixel que possui intensidade maior que ω . O aumento de contraste é dado pela seguinte expressão:

$$\text{Pixel atual} \leftarrow \text{Pixel atual} + \frac{\text{MaxIP} - \text{Pixel atual}}{3}. \quad (4.2)$$

O valor de ω definido para cada imagem no pré-processamento não foi utilizado como um detector automático, pois geralmente seu valor não é alto suficiente comparado aos demais detectores automáticos utilizado neste trabalho.

Como mostrado na seção 6, o método de pré-processamento adotado por este trabalho é eficiente em melhorar o desempenho dos detectores automáticos de RL. Sua aplicação foi satisfatória na maioria dos casos, melhorando os resultados obtidos em comparação com as mesmas imagens sem o método de pré-processamento.

4.3 Detectores Automáticos de RL

O processo de detecção automática consiste na implementação dos detectores automáticos de RL. Dois tipos de detectores automáticos de RL são utilizados neste trabalho. O detector escolhido na literatura, representado pelo detector por Limiar CT [4] definido anteriormente na seção 2.5.1 e os novos detectores propostos, representados por: Limiar CT Adaptado, Pico de Histograma Adaptado e Limiar Global.

4.3.1 Detector por Limiar CT Adaptado

Ao analisar a técnica de Chang e Tseng [4] em obter um limiar para identificar os RL, verificou-se uma possível fragilidade em seu método. Como a técnica de Chang e Tseng depende da MinIP para se obter o limiar, caso essa MinIP possua um valor alto, ele poderá comprometer o limiar final, sendo que o limiar não terá um valor alto suficiente para identificar apenas RL na cena. Esta situação pode ser verificada nos resultados da Tabela 1 e Tabela 2 da Seção 6 pelos baixos valores de Exatidão em alguns casos.

Para sustentar esta hipótese, foi desenvolvido uma adaptação do limiar CT com foco na MinIP, pois pretende-se mostrar que, em diferentes tipos de imagens, a MinIP pode obter valores variáveis, que podem comprometer o limiar final. Dessa forma, a adaptação sugere limitar o valor MinIP de uma cena, caso ela ultrapasse um valor pré-definido.

Foi feito um estudo no limiar CT e verificou-se que quando a MinIP possui valor acima de 15% da MaxIP, esse MinIP causa um impacto negativo no limiar, pois devido à subtração da MaxIP pela MinIP e depois multiplicação pelo fator de 0.8 ao valor resultante, é obtido um valor de limiar não tão alto suficiente para classificar apenas RL. Partindo desse princípio, foram testados valores máximos que o pixel de MinIP poderia assumir, com objetivo de não impactar de forma negativa o limiar. Os valores testados variam de 5%, 10% e 15% da MaxIP, sendo que o valor de 5% foi o que obteve melhores resultados, inclusive, em alguns casos, acima do que o limiar CT, como pode ser verificado nos resultados das Tabelas 1 e Tabela 2 da seção 6.

No Algoritmo 1, tem-se um exemplo de como foi feita a adaptação do limiar CT, sendo que, quando o MinIP possui intensidade maior que 5% do MaxIP, o mesmo terá seu valor fixado por 5% do MaxIP, caso contrário, a MinIP terá seu valor atual, já que se encontra nos limites definidos pelo autor. Dessa forma, após o ajuste da MinIP, pode-se aplicar a mesma equação como visto em (2.1).

Algoritmo 1: Controle do MinIP

Entrada: MinIP, MaxIP.
Saída: MinIP.

```

1 início
2   se ( $MinIP > MaxIP * 0.05$ ) então
3     |   MinIP = MaxIP * 0.05;
4   fim
5 fim
```

Considerando que o ajuste de 5% do valor de MaxIP da imagem obteve os melhores resultados entre os valores testados, também foi verificado se porcentagens de ajuste menores teriam melhores resultados. Dessa forma, porcentagens de 1% a 5% foram testadas. Entretanto, utilizando as imagens para experimento neste trabalho, a porcentagem de 5% atingiu melhores resultados na maioria dos casos e foi definida com ajuste final.

4.3.2 Pico do Histograma Adaptado

Este detector é uma adaptação da técnica verificada no trabalho proposto por Saint-Pierre et al. [7], onde o último pico do histograma dos três canais RGB indicam as regiões que existem RL na imagem. Ao invés do espaço de cor RGB, a representação de níveis de cinza foi adotada no Pico do Histograma Adaptado. Além disso, a análise original do último pico do histograma foi modificada.

A técnica de último pico de histograma foi aplicado apenas em imagens similares de processos cirúrgicos, onde o fundo da imagem era caracterizado pela cor vermelha do tecido interno do corpo humano e os RL pela cor branca. A análise de último pico de histograma proposto por Saint-Pierre et al. [7] pode ser comprometida quando aplicada

em cenários complexos que apresentam diferentes colorações de pixels. Dessa forma, algumas modificações foram propostas com intuito de estender esta aplicação para diferentes cenários.

A modificação proposta considera como RL a região do pico do histograma que cobre a maior quantidade de RL na imagem. A ideia de localizar os picos do histograma é baseada na representação de grandes quantidades de pixel com a mesma intensidade, caracterizando os RL. Um histograma pode apresentar mais de um pico, e para identificá-los, todos picos são avaliados. O primeiro pico é caracterizado pela primeira barra do histograma e seu fim é caracterizado pela troca de direção das barras de ascendente para descendente. Se houver outros picos, seus pontos iniciais serão as próximas barras referentes ao fim do último pico. Outra forma de se encontrar o fim de um pico ocorre quando a última barra do histograma é obtida.

Depois de encontrar os picos do histograma, uma varredura é feita para identificar qual pico cobre a maior quantidade de pixels. Os pixels com intensidades maiores que o valor de pixel que representa o pico deste histograma será considerado como RL.

A utilização do método de pré-processamento oferece uma estimativa de localização dos possíveis RL através do valor ω , definido na Expressão (4.1). Dessa forma, apenas picos que apresentam intensidade maiores que o valor ω serão avaliados como possíveis RL. As análises que não utilizam o método de pré-processamento avaliarão todos picos do histograma, sem uma estimativa de onde os RL estão.

4.3.3 Limiar Global

O Limiar Global é uma proposta nova para detecção de RL neste trabalho. Para se obter o valor do Limiar Global, dois passos são realizados. O primeiro passo obtém um Fator de Limiar que engloba parcialmente os pixels que possuem RL. Este Fator de Limiar é calculado por:

$$\text{Fator de Limiar} \leftarrow \frac{\text{MaxIP}}{2}. \quad (4.3)$$

Este primeiro passo é capaz de eliminar uma porção de pixels que não possuem RL, visto que são representados por valores de intensidade menores que o Fator de Limiar obtido pela Expressão (4.3). Se o MaxIP da imagem possuir um valor de intensidade de 255 as intensidades dos pixels que o Fator de Limiar irá englobar variarão entre 127 até 255, considerando que estes pixels estão transformados na representação de níveis de cinza.

Depois de adquirir este Fator de Limiar, o segundo passo se inicia, consistindo no ajuste da intensidade deste Fator de Limiar. Este ajuste é necessário para minimizar erros de classificações de pixels normais como RL. Para atingir este valor de ajuste, o valor de

intensidade do Fator de Limiar será adicionado com o valor resultante da divisão entre MaxIP e MinIP da imagem. O valor de MinIP precisa ser maior que 2, visto que em um cenário onde a MaxIP possui um valor de intensidade de 255 e fosse dividido por um valor MinIP menor ou igual a 2, um Limiar Global maior ou igual a 255 seria obtido e também não é possível realizar divisões pelo valor 0. Então, o detector classificaria apenas pixels com saturação total, que refere-se aos pixels com valores de intensidade iguais a 255. Também foi verificado que o valor de MinIP deve ser menor que 5, pois para valores maiores ou iguais a 5 um pequeno ajuste seria feito, o qual não seria capaz de separar os RL de pixels normais.

Diante deste cenário, o valor 3 foi determinado para ser utilizado como MinIP quando MinIP estiver fora do intervalo ($2 < \text{MinIP} < 5$), sendo que este é o menor valor possível para ser utilizado para prevenir que o detector encontre apenas pixels com saturação total. Assim, o Limiar Global é dado por:

$$\text{Limiar Global} \leftarrow \text{Fator de Limiar} + \frac{\text{MaxIP}}{\text{MinIP}}. \quad \text{MinIP} = \begin{cases} \text{MinIP} & \text{se } (2 < \text{MinIP} < 5) \\ 3 & \text{caso contrário} \end{cases} \quad (4.4)$$

De acordo com a expressão (4.4), o detector classificará como RL os pixels com intensidade maior que o Limiar Global e como pixels normais os que possuem intensidades menores que o Limiar Global.

5 AVALIAÇÃO DOS EXPERIMENTOS

Esta seção demonstra as avaliações dos experimentos dos detectores automáticos de RL em diferentes imagens. Primeiramente, as imagens utilizadas para realizar as detecções de RL são exibidas. Depois, as métricas de avaliação são discutidas para avaliação de performance de cada um dos detectores automáticos de RL.

5.1 Aquisição de Imagens

Um total de 23 imagens foram utilizadas para comparação neste trabalho. Elas foram divididas em quatro grupos. O primeiro grupo consiste de seis imagens adquiridas pelo autor, sendo uma delas cedidas pelo grupo de pesquisa REMID UEL, em diferentes cenários com incidência de RL.

O segundo grupo foi obtido por meio do repositório online *Yale Face Database* [17], que contém imagens de faces humanas submetidas a diferentes condições de luminosidade. Neste trabalho, existem sete imagens desta base.

O terceiro grupo foi obtido a partir do *Flickr Material Database (FMD)* [18]. O *FMD* consiste de fotografias coloridas de superfícies pertencentes a dez categorias distintas: tecido, folhagem, vidro, couro, metal, papel, plástico, pedra, água e madeira. Todas as imagens apresentam variação de condições de luminosidade, composições, colorações, texturas e formatos de superfícies diferentes. O terceiro grupo também possui sete imagens para experimentação neste trabalho.

O quarto grupo foi obtido pelo *The Atlas of Gastrointestinal Endoscopy*, que é um repositório online de imagens de procedimentos de endoscopia. Todas as fotografias de endoscopia foram feitas pelos doutores Martin e Lyons [19]. Estas imagens de endoscopia apresentam incidência de RL pela cena.

O conjunto de Figuras 7 apresentam as seis imagens pertencentes ao primeiro grupo. Foram escolhidos três materiais feitos de plásticos, uma imagem sintética criada em um editor de imagens, um cilindro metálico e uma imagem de uma porção de um peito de frango, que consiste na imagem cedida pelo grupo de pesquisa REMID UEL.

O conjunto de Figuras 8 apresentam as imagens do segundo grupo, consistindo de imagens de faces humanas. As imagens apresentam diferentes focos de saturação causadas pelos RL espalhadas pela cena.

O conjunto de Figuras 9 apresentam as sete imagens pertencentes ao terceiro grupo. As imagens consistem de duas imagens com um diferente pedaço de couro em cada, duas imagens com um pedaço de vidro em cada, um objeto metálico, uma imagem de tecido e




(a) Imagem de uma caneca




(b) Imagem de um bule



(c) Imagem de um pote



(d) Imagem sintética



(e) Imagem de um cilindro metálico



(f) Imagem de peito de frango

Figura 7 – Sequência de imagens utilizadas para experimento do primeiro grupo de imagens.

um objeto de plástico. Todas imagens apresentam focos de luminosidade espalhados pela cena.

O conjunto de Figuras 10 apresentam imagens de procedimentos de endoscopia que consistem de uma imagem de Duodenite, Varizes gástricas e Angiodisplasia.

5.2 Métricas de avaliação

Para se obter as métricas de avaliação, as informações recebidas das detecções manuais foram utilizadas, pois apresentam um indicador de respostas de quais pixels da imagem possuem RL ou não. As métricas utilizadas neste trabalho são Acurácia, Precisão, RMSE e Exatidão. De acordo com os detectores automáticos propostos neste trabalho, as seguintes classificações de pixels podem ser obtidas:

- A classificação VP (Verdadeiro Positivo), que corresponde ao acerto nas classificações dos pixels que possuem RL;
- A classificação FP (Falso Positivo), que corresponde ao erro nas classificações dos pixels que não possuem RL;
- A classificação VN (Verdadeiro Negativo), que corresponde ao acerto nas classificações dos pixels normais;

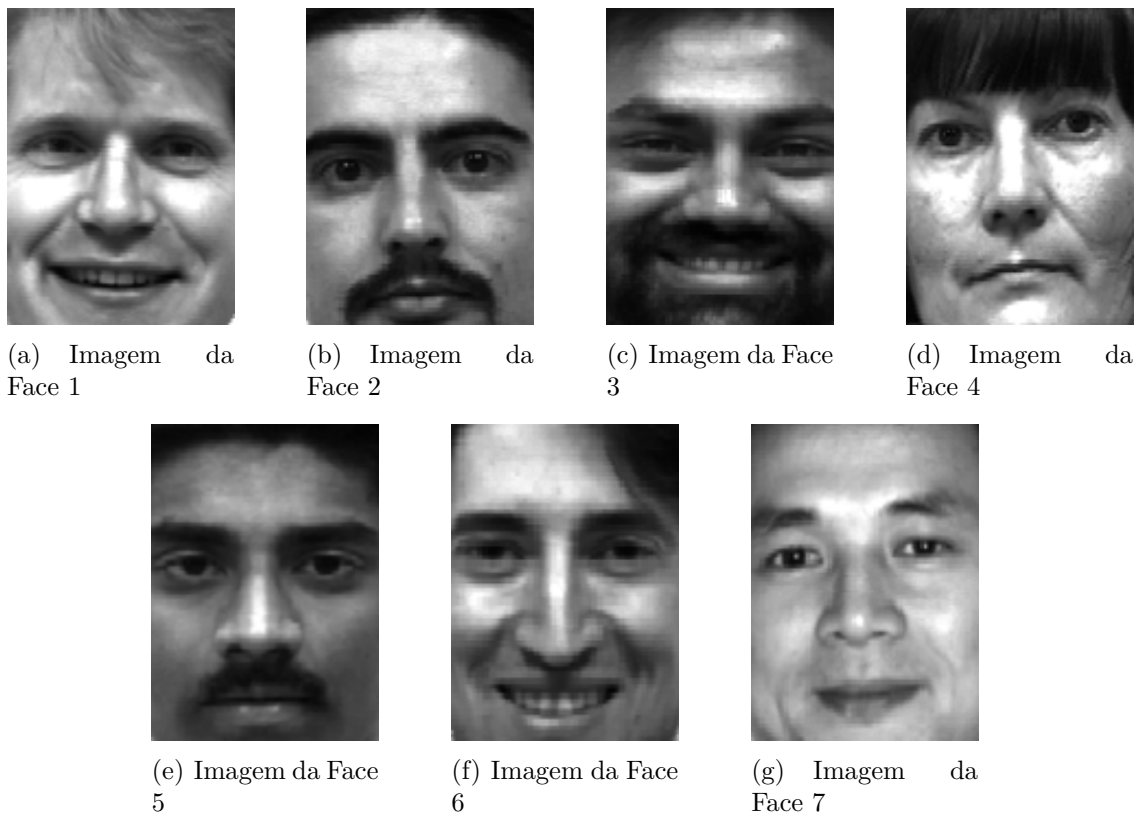


Figura 8 – Sequência de imagens utilizadas para experimento do segundo grupo de imagens.

- A classificação FN (Falso Negativo), que corresponde ao erro nas classificações de pixels normais.

A métrica de Acurácia corresponde a proporção de predições corretas entre todos os pixels da imagem. Esta métrica oferece um comportamento de desempenho geral. Entretanto, para dados desbalanceados, onde a quantidade de uma característica é muito maior que outra, esta métrica pode apresentar altos valores, mesmo quando suas predições não forem evidenciadas. Neste trabalho, o problema de RL em imagens é um dado desbalanceado comparado a quantidade de pixels normais em uma imagem, visto que os RL aparecem em uma quantidade menor. A métrica de Acurácia [20] é dada por:

$$\text{Acurácia} \leftarrow \frac{VP + VN}{VP + VN + FP + FN} \quad (5.1)$$


A métrica de Precisão corresponde a proporção de predições corretas de RL em todos pixels detectados. Todavia, a métrica de Precisão não avalia predições que não foram marcadas. Sendo assim, a métrica de Precisão não oferece informação completa sobre identificações de RL pelos detectores automáticos. A métrica de Precisão é dada




(a) Imagem de um material de couro vermelho




(b) Imagem de um material de couro marrom




(c) Imagem de um material de vidro



(d) Imagem de um vidro azul



(e) Imagem de um material metálico



(f) Imagem de um tecido




(g) Imagem de um plástico

Figura 9 – Sequência de imagens utilizadas para experimento do terceiro grupo de imagens.



(a) Duodenite



(b) Varizes gástricas



(c) Angiodisplasia

Figura 10 – Sequência de imagens utilizadas para experimento do quarto grupo de imagens.

por:

$$\text{Precisão} \leftarrow \frac{VP}{VP + FP} \quad (5.2)$$

A métrica RMSE calcula a raiz quadrada da média do quadrado das diferenças correspondentes aos elementos previstos e observados, de acordo com Barnston [21].

Os elementos previstos correspondem às classificações feitas pelos detectores automáticos, enquanto os elementos observados correspondem às classificações feitas pela detecção manual. As saídas geradas pelos detectores automáticos e detecção manual são imagens binárias. Os elementos previstos e observados da imagem são representados por z_{fi} e z_{foi} , respectivamente. Quanto mais próximo de 0 o valor da métrica RMSE, melhor o desempenho dos elementos previstos. Infelizmente, a métrica RMSE não garante que os resultados obtidos são específicos da análise de pixels que possuem RL. Dessa forma, a resposta obtida por esta métrica pode ser contraditória.

$$\text{RMSE} \leftarrow \sqrt{\frac{\sum_{i=1}^n (z_{fi} - z_{foi})^2}{N}}. \quad (5.3)$$

As métricas de Acurácia e Precisão já são consolidadas na literatura [20]. Porém, elas apresentam algumas peculiaridades quando avaliadas em classificações de RL em imagens. A métrica RMSE não faz avaliações apenas de pixels que possuem RL, comprometendo assim o resultado final. Dessa forma, se mostrou necessário a criação de uma métrica que superasse estes problemas.

A métrica de Exatidão é uma métrica nova desenvolvida neste trabalho e apresenta informações completas sobre as detecções feitas pelos detectores automáticos. Esta métrica não apresenta problemas para dados desbalanceados, como visto na métrica de Acurácia. Esta métrica também avalia pixels que não foram identificados pelos detectores automáticos, diferentemente da métrica de Precisão, visto que esta segunda avalia apenas previsões marcadas. Os acertos e erros são avaliados de acordo com todos RL presentes na imagem, utilizando as informações da detecção manual. A abreviação DMRL representa o número de detecções manuais de RL.

Para agilizar o cálculo da métrica de Exatidão verifica-se primeiro se a quantidade de classificações FP é maior que VP, visto que neste caso a quantidade de erros do detector automático seria maior do que seus acertos. Caso isso ocorra, a métrica de Exatidão adquire uma taxa de 0% de resultado. Porém, se a quantidade de classificações de VP for maior, a obtenção do resultado da métrica de Exatidão é dada por:

$$\text{Exatidão} \leftarrow \frac{\text{VP} - \text{FP}}{\text{DMRL}}. \quad (5.4)$$

Entre todas as quatro métricas definidas neste trabalho, a métrica de Exatidão avalia mais informações para demonstrar o desempenho dos acertos das classificações dos detectores automáticos.

5.2.1 Detector por Limiar de Referência

Além dos detectores automáticos de RL propostos neste trabalho, um detector de Limiar de Referência também foi proposto. Esta métrica de Limiar de Referência utiliza informações da métrica de Exatidão, definida anteriormente. Dessa forma, todas as intensidades de luminosidade que um pixel pode assumir na representação de níveis de cinza em uma imagem, que varia de 0 à 255, são avaliadas. Depois de avaliar todos estes valores de intensidade, é possível verificar o melhor limiar de intensidade de luminosidade para separar RL de pixels normais em cada imagem.

A utilização do Limiar de Referência serve como um avaliador de desempenho dos demais detectores automáticos de RL, visto que ele obtém a melhor taxa de Exatidão para cada imagem. Os demais detectores automáticos de RL propostos neste trabalho obtiveram, no máximo, uma taxa de Exatidão equivalente ao do detector por Limiar de Referência.

6 RESULTADOS E DISCUSSÕES

As Tabelas 1 e 2 apresentam os resultados quantitativos obtidos pelos detectores automáticos de RL das imagens submetidas para experimentação citadas na subseção 5.1, consistindo em um total de 23 imagens. Estes resultados se referem à taxa de acerto das classificações dos pixels como RL ou não, utilizando a detecção manual como modelo de referência. As métricas disponíveis nestas tabelas são: Acurácia, Precisão, Exatidão e RMSE, como descrito na subseção 5.2.

As abreviações LR, LG, LCT, LCTA e PHA, respectivamente, descrevem o Limiar de Referência, Limiar Global, Limiar Chang-Tseng, Limiar Chang-Tseng Adaptado e Pico do Histograma Adaptado. Da mesma forma, as imagens que foram submetidas ao método de pré-processamento são representadas por CPP (com pré-processamento), enquanto as que não foram serão representadas por SPP (sem pré-processamento). Para simplificar, as abreviações dos detectores automáticos serão concatenados com as abreviações que indicam a utilização ou não do método de pré-processamento, como por exemplo, LGCPP (Limiar Global com pré-processamento).

Os melhores e piores resultados de Exatidão dos detectores automáticos para cada imagem avaliada será destacado em negrito. Com isso, os resultados extremos ficam evidenciado para facilitar o entendimento dos dados obtidos. Apenas os resultados de Exatidão serão destacados, pois é a métrica que apresenta com maiores informações o desempenho de um detector automático, como visto na definição das Métricas de Avaliação na Seção 5.2.

Analisando os resultados das Tabelas 1 e 2 e considerando que o LR obtém a melhor taxa de Exatidão possível para um detector automático, o Detector LGCPP apresentou taxas significativas de Exatidão, visto que este obteve melhores taxas de Exatidão na maioria dos casos. Suas taxas de Exatidão foram equivalentes ao detector por LR nas imagens da Tabela 1, Caneca, Cilindro metálico, Face 2, Face 3, e da Tabela 2, Varizes gástricas e Angiodisplasia. Apenas na imagem Face 6, a taxa de Exatidão do detector LGCPP foi menor que outro detector automático.

Em algumas situações, houveram taxas de Exatidão de 0%, como por exemplo, na Imagem sintética, pelo detector LCT. Este fato ocorre quando o detector obtém mais Falsos Positivos do que Verdadeiros Positivos em suas classificações. Dessa forma, a taxa de Exatidão adquire um valor negativo, o qual é representado pelo valor de 0%, caracterizando que este detector não manteve uma boa qualidade em suas classificações.

Existem também situações em que a métrica de Acurácia ou de Precisão obtiveram taxas de 100%. Porém, estes resultados podem conduzir interpretações contraditórias,

como visto na seção 5.2. Isto ocorre porque um detector automático pode ter acertado todas suas marcações, entretanto, o número de pixels que não foram marcados é maior. Dessa forma, a métrica de Exatidão é capaz de demonstrar quando resultados de 100% nas métricas de Acurácia ou Precisão são expressivos ou não. Um exemplo deste caso pode ser verificado na imagem do Pote da Tabela 1, onde sua taxa de Precisão foi de 100%. Todavia, sua taxa de Exatidão foi de 0% utilizando o detector automático PHASPP.

Uma característica verificada nos resultados consiste na taxa de Exatidão do detector automático LGCPP ter obtido melhores resultados do que o detector automático LCT até mesmo no segundo grupo de imagens. Este segundo grupo é composto de imagens de faces humanas expostas a diferentes condições de luminosidade e que consiste na aplicação específica da da técnica LCT.

De modo geral, ao avaliar a Média Final para cada detector avaliado, é possível verificar que a melhoria dos detectores LGCPP e PHACPP comparado as suas versões SPP utilizando a métrica de Exatidão foram de 15,19% e 42,36%, respectivamente. Comprovando de fato que a utilização do pré-processamento foi significativo nestes detectores.

Depois de detectar os RL das imagens dos quatro grupos utilizando os detectores automáticos de RL, foi feito um gráfico de barras para a métrica de Exatidão. Estes gráficos de barras englobam a média dos resultados obtidos pelos detectores nos grupos de imagens avaliados. Além disso, os gráficos de barras permitem uma melhor avaliação visual dos resultados obtidos por cada detector automático de RL.

Na Figura 11, é demonstrado a taxa média da métrica de Exatidão do primeiro grupo. O detector por LGCPP adquiriu melhores taxas de Exatidão neste grupo de imagens, juntamente com o detector por LR. O detector LCTASPP também adquiriu resultados significantes, porém menores que ao detector LGCPP. Além disso, é possível notar o baixo desempenho dos detectores LCTCPP e LCTACPP, demonstrando que o método de pré-processamento não foi favorável para estes detectores. Entretanto, é possível verificar que os detectores LGCPP e PHACPP obtiveram aumentos significativos em seus acertos com a utilização do pré-processamento proposto.

Tendo em vista que a métrica de Exatidão é capaz de relatar com mais informações o desempenho dos detectores automáticos, de modo geral, no primeiro grupo de imagens, temos que o LGCPP apresentou o melhor desempenho nas classificações de RL. Seus resultados ficaram próximos ao detector por LR, demonstrando uma boa qualidade em suas detecções. A seguir serão apresentados os resultados médios da métrica de Exatidão para o segundo grupo de imagens.

Na Figura 12, é demonstrado a taxa média da métrica de Exatidão do segundo grupo. O detector por LGCPP adquiriu mais uma vez melhores taxas de Exatidão nas imagens avaliadas, juntamente com o detector por LR. Neste segundo grupo foram obtidos

Tabela 1 – Resultados obtidos pelos detectores automáticos de RL do primeiro e segundo grupo de imagens.

		LR		LG		LCT		LCTA		PHA	
		SPP	CPP	SPP	CPP	SPP	CPP	SPP	CPP	SPP	CPP
Caneca	Acurácia	99,90%	99,90%	99,64%	99,90%	99,88%	99,73%	99,88%	99,73%	99,15%	99,35%
	Precisão	92,97%	92,97%	97,88%	92,97%	94,64%	73,82%	94,64%	73,82%	100,00%	95,14%
	Exatidão	86,25%	86,25%	52,64%	86,25%	84,52%	64,42%	84,52%	64,42%	3,00%	77,65%
	RMSE	0,3679	0,3679	3,8192	0,3679	0,3122	0,8243	0,3122	0,8243	23,1535	3,1621
Bule	Acurácia	99,97%	99,97%	99,94%	99,97%	99,97%	99,93%	99,97%	99,93%	99,22%	99,37%
	Precisão	94,88%	94,88%	97,91%	94,39%	96,73%	78,85%	96,73%	78,85%	97,53%	95,43%
	Exatidão	90,55%	90,55%	77,45%	90,29%	89,04%	72,82%	89,04%	72,82%	46,35%	88,27%
	RMSE	0,1877	0,1877	0,9624	0,1972	0,1458	15,4846	0,1458	15,4846	18,8765	2,2182
Pote	Acurácia	99,53%	99,53%	97,94%	99,52%	99,25%	99,26%	99,25%	99,26%	96,21%	99,03%
	Precisão	91,63%	91,63%	100,00%	93,57%	82,12%	66,19%	82,12%	66,19%	100,00%	93,94%
	Exatidão	86,29%	86,29%	39,57%	85,80%	78,05%	48,92%	78,05%	48,92%	0,00%	65,28%
	RMSE	0,8688	0,8688	6,7754	0,7419	1,3746	5,6603	1,3746	5,6603	12,7170	0,1566
Imagem sintética	Acurácia	99,86%	99,86%	99,40%	99,85%	97,66%	95,04%	99,84%	99,72%	98,13%	99,17%
	Precisão	95,53%	95,53%	100,00%	96,90%	41,89%	25,41%	98,21%	85,92%	100,00%	94,44%
	Exatidão	91,53%	91,53%	64,27%	91,39%	0,00%	0,00%	90,26%	83,61%	16,45%	85,32%
	RMSE	0,4400	0,4400	1,4989	0,3606	2,4451	3,5571	0,2691	0,8218	23,4365	0,5573
Cilindro metálico	Acurácia	99,31%	99,31%	98,55%	99,31%	99,10%	98,29%	99,10%	98,29%	97,16%	99,06%
	Precisão	89,20%	89,20%	92,51%	89,20%	93,09%	68,77%	93,09%	68,77%	84,76%	91,17%
	Exatidão	81,47%	81,47%	60,78%	81,47%	75,77%	53,77%	75,77%	53,77%	21,35%	79,87%
	RMSE	1,0301	1,0301	1,8725	1,0301	0,7578	2,0570	0,7578	2,0570	13,4247	1,6564
Peito de frango	Acurácia	99,69%	99,69%	99,14%	99,69%	99,56%	97,47%	99,56%	97,47%	97,31%	99,13%
	Precisão	93,37%	93,37%	99,17%	91,25%	90,97%	51,97%	90,97%	51,97%	100,00%	90,84%
	Exatidão	88,85%	88,85%	68,67%	88,75%	87,33%	7,57%	87,33%	7,57%	0,00%	87,32%
	RMSE	0,6884	0,6884	1,7264	0,8103	0,7267	2,5399	0,7267	2,5399	2,3521	0,9325
Face 1	Acurácia	97,45%	97,45%	95,95%	97,02%	96,78%	95,00%	96,78%	95,00%	92,36%	93,17%
	Precisão	94,59%	94,59%	99,64%	85,06%	82,13%	71,05%	82,13%	71,05%	90,17%	91,22%
	Exatidão	77,44%	77,44%	64,10%	73,62%	72,56%	55,70%	72,56%	55,70%	37,23%	67,52%
	RMSE	1,1631	1,1631	1,8923	2,1248	0,7470	3,3204	0,7470	3,3204	9,2123	2,4231
Face 2	Acurácia	97,34%	97,34%	93,45%	97,34%	95,62%	96,30%	95,62%	96,30%	90,23%	97,08%
	Precisão	95,25%	95,25%	99,86%	95,25%	99,37%	85,99%	99,37%	85,99%	100,00%	92,12%
	Exatidão	84,99%	84,99%	63,11%	84,99%	75,32%	79,17%	75,32%	79,17%	32,51%	74,18%
	RMSE	1,4212	1,4212	3,8912	1,4212	0,4667	1,6513	0,4667	1,6513	6,4882	0,6770
Face 3	Acurácia	98,33%	98,33%	94,49%	98,33%	96,46%	96,58%	96,46%	96,58%	93,17%	92,57%
	Precisão	93,92%	93,92%	99,10%	93,92%	98,64%	74,74%	98,64%	74,74%	100,00%	89,67%
	Exatidão	83,29%	83,29%	44,77%	83,29%	64,53%	65,76%	64,53%	65,76%	23,87%	71,54%
	RMSE	1,2106	1,2106	4,1274	1,2106	0,4799	2,9226	0,4799	2,9226	11,2764	1,8422
Face 4	Acurácia	97,07%	97,07%	96,23%	96,36%	93,76%	94,44%	93,76%	94,44%	92,17%	90,28%
	Precisão	94,65%	94,65%	98,28%	83,89%	89,17%	73,72%	89,17%	73,72%	99,10%	87,65%
	Exatidão	79,85%	79,85%	74,07%	74,98%	73,72%	61,80%	73,72%	61,80%	43,39%	66,38%
	RMSE	1,3325	1,3325	1,3924	2,5713	1,4363	3,1780	1,4363	3,1780	7,8242	4,1532
Face 5	Acurácia	99,78%	99,78%	99,66%	99,75%	99,75%	99,03%	99,75%	99,03%	93,28%	99,33%
	Precisão	92,26%	92,26%	95,93%	92,05%	92,05%	52,90%	92,05%	52,90%	100,00%	91,56%
	Exatidão	79,88%	79,88%	68,90%	77,44%	77,44%	10,98%	77,44%	10,98%	57,63%	76,34%
	RMSE	0,4505	0,4505	1,3252	0,6502	0,6502	1,5713	0,6502	1,5713	2,2142	0,7214
Face 6	Acurácia	97,20%	97,20%	91,41%	97,05%	94,50%	96,29%	94,50%	96,29%	98,17%	93,94%
	Precisão	94,37%	94,37%	100,00%	97,45%	100,00%	84,84%	100,00%	84,84%	100,00%	92,64%
	Exatidão	83,87%	83,87%	50,58%	83,02%	68,36%	78,24%	68,36%	78,24%	52,44%	82,32%
	RMSE	1,5350	1,5350	3,7892	0,9950	3,1723	2,7467	3,1723	2,7467	3,6491	1,8723

mais uma vez as mesmas características semelhantes ao primeiro grupo de imagens. Baixo desempenho dos detectores LCTCPP e LCTACPP e melhoras significativas nos detectores PHACPP e LGCPP. A seguir serão apresentados os resultados médios da métricas de Exatidão do terceiro grupo de imagens.

Na Figura 13, é demonstrado a taxa média da métrica de Exatidão do terceiro grupo. O detectores LGCPP e LCTASPP adquiriram melhores taxas de Exatidão neste grupo de imagens, juntamente com o detector por LR. Um péssimo desempenho do detector LCT é evidenciado. Uma característica importante nesse resultado é que este grupo de imagens apresenta a maior complexidade na detecção de RL comparado aos demais. Além disso, o detector LCTA obteve resultados bons comparado aos demais, especialmente o LCTASPP. Isto demonstra que a hipótese levantada por este trabalho se mostrou verdadeira, sendo que a adaptação do detector LCT adquiriu melhores resultados quando

Tabela 2 – Resultados obtidos pelos detectores automáticos de RL do segundo, terceiro e quarto grupo de imagens.

		LR		LG		LCT		LCTA		PHA	
		SPP	CPP	SPP	CPP	SPP	CPP	SPP	CPP	SPP	CPP
Face 7	Acurácia	95,50%	95,50%	88,13%	95,18%	94,61%	95,02%	94,61%	95,02%	82,33%	85,21%
	Precisão	87,45%	87,45%	99,65%	92,05%	89,98%	90,87%	89,98%	90,87%	34,50%	89,17%
	Exatidão	75,56%	75,56%	35,50%	73,79%	72,15%	73,17%	72,15%	73,17%	22,87%	70,17%
	RMSE	2,1154	2,1154	2,9854	2,0981	2,7467	2,3341	2,7467	2,3341	5,5992	3,0012
Couro vermelho	Acurácia	96,00%	96,00%	94,85%	95,18%	74,82%	74,82%	95,66%	93,76%	87,39%	91,13%
	Precisão	93,56%	93,56%	97,54%	92,33%	49,25%	49,25%	89,47%	81,16%	77,27%	84,89%
	Exatidão	83,64%	83,64%	78,93%	80,26%	0,00%	0,00%	81,24%	74,48%	17,43%	72,33%
	RMSE	1,9620	1,9620	1,1291	1,2197	8,0070	8,0070	2,6139	3,1125	7,1423	2,6452
Couro marrom	Acurácia	99,19%	99,19%	98,58%	99,18%	87,09%	87,09%	99,18%	98,22%	89,73%	93,47%
	Precisão	91,92%	91,92%	98,32%	91,07%	25,62%	25,62%	92,54%	81,21%	90,29%	88,16%
	Exatidão	81,77%	81,77%	67,94%	81,64%	0,00%	0,00%	81,51%	74,42%	53,44%	70,17%
	RMSE	0,9453	1,8267	2,1992	1,0032	5,7366	5,7366	0,8996	1,9151	3,9482	2,3459
Vidro 1	Acurácia	99,61%	99,61%	99,59%	99,00%	99,61%	99,61%	99,10%	98,25%	65,44%	87,33%
	Precisão	94,66%	94,66%	96,60%	76,65%	94,66%	94,66%	78,74%	64,93%	21,36%	82,34%
	Exatidão	87,84%	87,84%	87,40%	69,00%	87,84%	87,84%	70,27%	45,90%	2,23%	63,44%
	RMSE	0,6582	0,6582	0,6095	1,5971	0,6582	0,6582	1,4853	2,1092	9,1257	1,4823
Vidro 2	Acurácia	99,81%	99,81%	99,72%	99,76%	47,70%	47,70%	99,66%	99,40%	77,78%	96,17%
	Precisão	94,08%	94,08%	98,78%	87,63%	2,56%	2,56%	86,77%	69,85%	41,22%	84,57%
	Exatidão	86,15%	86,15%	79,40%	82,50%	0,00%	0,00%	81,27%	56,26%	32,98%	80,37%
	RMSE	0,4513	0,4513	0,8252	0,6909	11,5813	11,5813	0,6175	1,2266	7,1530	1,6261
Metal	Acurácia	96,39%	96,39%	94,80%	96,16%	88,78%	88,78%	96,28%	94,83%	83,45%	90,39%
	Precisão	93,00%	93,00%	96,56%	90,22%	69,41%	69,41%	91,17%	84,54%	65,32%	87,99%
	Exatidão	85,68%	85,68%	79,35%	84,76%	55,44%	55,44%	84,24%	79,49%	33,17%	81,53%
	RMSE	1,3024	1,3024	1,2319	1,4147	5,2962	5,2962	1,2004	2,7881	6,7142	1,8023
Tecido	Acurácia	96,16%	96,16%	94,36%	95,66%	48,67%	48,67%	94,41%	93,14%	80,17%	94,05%
	Precisão	90,71%	90,71%	80,57%	84,35%	25,66%	25,66%	80,20%	73,11%	54,17%	77,89%
	Exatidão	78,31%	78,31%	70,72%	75,50%	0,00%	0,00%	72,08%	61,30%	33,11%	69,33%
	RMSE	2,0094	2,0094	1,2317	2,7871	11,4407	11,4407	2,9621	4,0139	5,1923	2,7909
Plástico	Acurácia	99,78%	99,78%	99,46%	99,73%	67,71%	67,71%	99,66%	98,47%	73,46%	93,55%
	Precisão	93,94%	93,94%	99,17%	89,73%	5,66%	5,66%	89,68%	55,95%	34,92%	83,64%
	Exatidão	88,66%	88,66%	71,92%	85,91%	0,00%	0,00%	85,67%	21,12%	27,41%	82,37%
	RMSE	0,5497	0,5497	0,9529	0,7407	9,0746	9,0746	0,5907	1,9656	6,1520	1,0152
Duodenite	Acurácia	99,93%	99,93%	99,72%	99,93%	99,81%	99,53%	99,81%	99,53%	99,82%	99,85%
	Precisão	92,76%	92,76%	100,00%	92,76%	100,00%	57,94%	100,00%	57,94%	90,88%	92,22%
	Exatidão	89,04%	89,04%	57,53%	89,04%	71,23%	27,40%	71,23%	27,40%	80,37%	86,51%
	RMSE	0,3531	0,3531	5,1272	0,3531	0,4782	1,0961	0,4782	1,0961	0,5988	0,4912
Varizes gástricas	Acurácia	99,82%	99,82%	99,56%	99,79%	99,57%	99,15%	99,57%	99,15%	99,32%	99,73%
	Precisão	96,66%	96,66%	100,00%	92,58%	81,14%	68,03%	81,14%	68,03%	80,17%	91,53%
	Exatidão	89,85%	89,85%	75,25%	88,12%	75,99%	52,48%	75,99%	52,48%	73,24%	85,24%
	RMSE	0,3838	0,3838	0,8125	0,3838	1,0062	1,4597	1,0062	1,4597	1,1522	0,7612
Angiodisplasia	Acurácia	99,76%	99,76%	99,32%	99,76%	99,49%	98,56%	99,49%	98,56%	99,57%	99,68%
	Precisão	91,69%	91,69%	98,19%	91,69%	96,67%	53,15%	96,67%	53,15%	88,29%	91,55%
	Exatidão	84,97%	84,97%	58,20%	84,97%	68,85%	11,75%	68,85%	11,75%	78,17%	82,18%
	RMSE	0,5927	0,5927	1,0192	0,5927	0,3194	1,9044	0,3194	1,9044	0,9190	0,6535
Média Final	Acurácia	98,56%	98,56%	97,13%	98,10%	86,25%	85,27%	97,89%	97,19%	90,65%	95,31%
	Precisão	93,18%	93,18%	96,34%	90,74%	70,00%	54,73%	91,02%	73,34%	80,43%	89,56%
	Exatidão	84,60%	84,60%	67,28%	82,47%	51,80%	35,58%	72,04%	51,13%	34,29%	76,65%
	RMSE	0,9574	0,9574	2,2259	1,1027	3,3315	4,5262	1,1076	2,9002	8,1879	1,6081

um controle no MinIP é necessário. A seguir serão apresentados os resultados médios da métrica de Exatidão para o quarto grupo de imagens.

Na Figura 14, é demonstrado a taxa média da métrica de Exatidão do quarto grupo. O detector por LGCPP adquiriu melhores taxas de Exatidão mais uma vez, juntamente com o detector por LR. Neste grupo de imagens também foi notado mais uma vez um baixo desempenho do detector LCT e dessa vez também do LCTA. Mesmo aplicando o controle do MinIP no detector LCTA.

Para finalizar a exibição de resultados quantitativos, será apresentado a seguir, figuras que apresentam gráficos de barras finais para cada métrica de avaliação utilizada neste trabalho. Esse último gráfico de barras engloba a média de resultados obtidos pelos detectores a partir de todos os grupos de imagens. Primeiramente, é exibido o gráfico de barras com a média final da métrica de Acurácia.




Figura 11 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no primeiro grupo de imagens.




Figura 12 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no segundo grupo de imagens.

De acordo com a Figura 15, os detectores LGCPP e LCTA apresentaram os melhores resultados de Acurácia comparado aos outros detectores.

A Figura 16, apresenta a média da taxa de Precisão final. Dessa vez o detector que obteve melhor desempenho foi o LGSPP.

A Figura 17, demonstra a média da taxa de Exatidão final. O detector LGCPP mais uma vez foi o que obteve destaque, sendo que nos quatro grupos de imagens ele

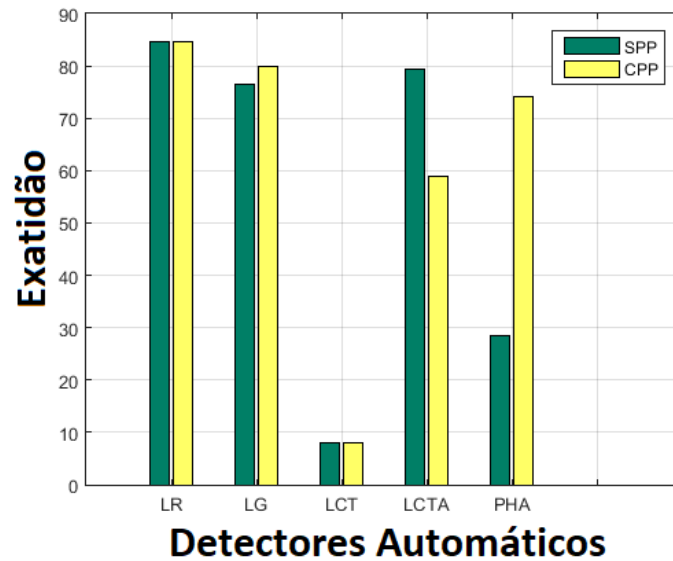


Figura 13 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no terceiro grupo de imagens.

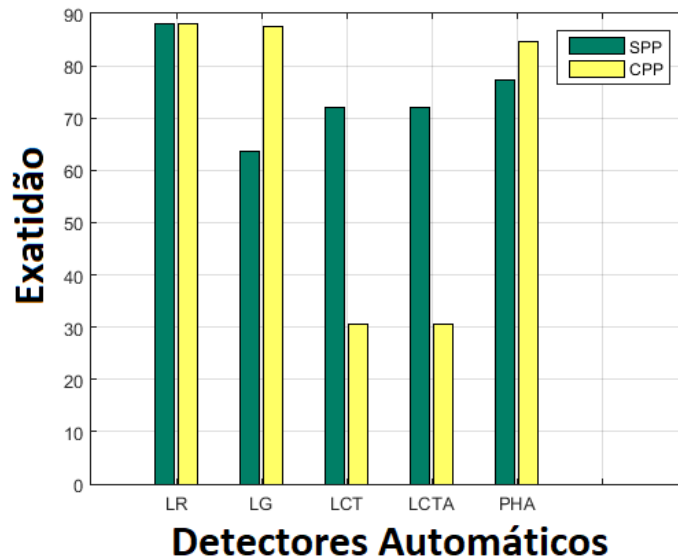


Figura 14 – Gráfico de barras da média de Exatidão de cada um detectores automáticos no quarto grupo de imagens.

adquiriu as melhores taxas de Exatidão, juntamente com o detector LR. Além dessa informação, é possível verificar também que mesmo o detector LGCPP não ter obtido as melhores taxas nas métricas de Precisão e Acurácia, foi capaz de ter a melhor taxa de Exatidão. Isto demonstra, de fato, que as métricas de Acurácia e Precisão não podem ser avaliadas isoladamente, devido a seus problemas já comentados anteriormente.

Além disso, é possível verificar nesta figura que a adaptação do detector LCT,




Figura 15 – Gráfico de barras da métrica da média final de Acurácia de cada um dos detectores automáticos.




Figura 16 – Gráfico de barras da métrica da média final de Precisão de cada um dos detectores automáticos.

representada pelo detector LCTA, de um modo geral, obteve melhores resultados que a técnica original proposta por Chang e Tseng [4].

Por fim, a Figura 18, apresenta a média da taxa de RMSE final. Os detectores LGCPP e LCTA apresentaram os resultados mais próximos de zero.

Analisando as taxas da métrica de Exatidão para o detector LCT, foi verificado que o método de pré-processamento não garantiu melhoras em seu desempenho. Isto ocorre




Figura 17 – Gráfico de barras da métrica da média final de Exatidão de cada um dos detectores automáticos.

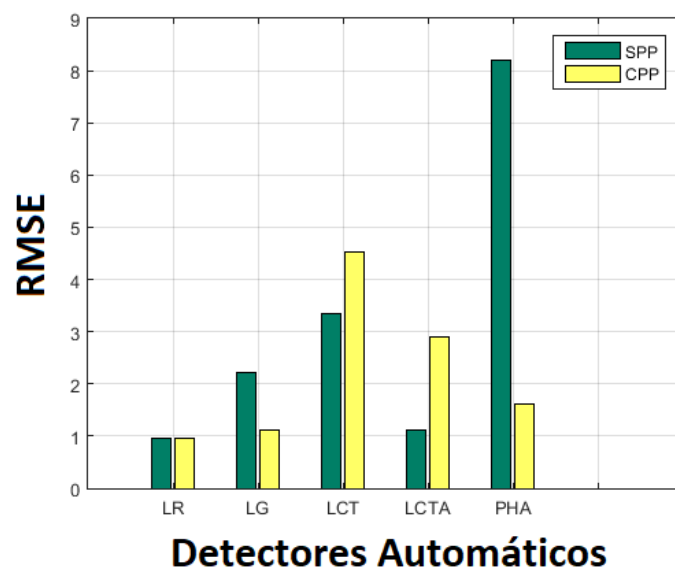


Figura 18 – Gráfico de barras da métrica da média final de RMSE de cada um dos detectores automáticos.

porque o LCT tende a obter um valor de intensidade alto o suficiente para identificar boa parte dos RL na imagem. Quando utilizado conjuntamente com o pré-processamento proposto, este detector adquire um valor de intensidade maior do que o ideal, deixando de marcar uma certa quantia de RL, justificando os resultados obtidos. Entretanto, para os detectores LG e PHA, o método de pré-processamento apresentou ganhos significativos em detectar RL. Na maioria dos casos, ambos detectores obtiveram aumento na taxa de Exatidão em suas detecções.

O detector LR não apresentou mudanças em seus resultados entre imagens CPP e SPP, pois este detector sempre obtém o melhor limiar possível. Além disso, sendo que o pré-processamento aumenta a intensidade dos pixels com potencial capacidade de serem RL, a única diferença entre imagens CPP e SPP é o fato de que o valor SPP será menor que o CPP, mesmo representando o mesmo pixel. Por este fato, as métricas obtiveram os mesmos resultados.

Diante os resultados, o método de pré-processamento é aplicável para os detectores LG e PHA. O detector por LGCPP apresentou melhores resultados na maioria dos testes, independentemente do tipo de cenário ou complexidade da imagem.

Dessa forma, o detector por LGCPP foi selecionado para demonstrar os resultados qualitativos das classificações de RL nos quatro grupo de imagens, visto que o seu desempenho foi o melhor entre os demais detectores. Será demonstrado uma sequência de quatro subfiguras para cada imagem. Para cada imagem, são demonstrados a seguinte sequência: a imagem original, a detecção manual, a detecção por LR e detecção por LGCPP dessa imagem, respectivamente.

Todas os resultados exibidos apresentam grande tendência entre a imagem original e as marcações dos detectores de RL, visto que os RL são caracterizados pela coloração branca e os pixels normais pela coloração preta nas imagens de detecções de RL. Esta similaridade se dá pelo bom desempenho do detector LGCPP em detectar corretamente os RL, na maioria dos casos, tornando perceptível as regiões da imagem original que possuem RL.

Os resultados foram satisfatórios até mesmo no terceiro grupo de imagens, Figuras 32-38, pois trata-se do grupo que possui maior complexidade para identificação dos RL. Dessa forma, a seguir serão exibidas as 23 imagens utilizadas para experimentação. Todas estas imagens estarão acompanhadas de sua detecção manual, a detecção por LR e detecção por LGCPP, respectivamente.

6.1 Limitações do trabalho

Apesar dos detectores automáticos de RL propostos obterem bons resultados em diferentes cenários, um desafio recorrente na classificação de RL, encontrado até mesmo nas técnicas verificadas na literatura [22], consiste na diferenciação de RL de pixels com a coloração branca de uma imagem. Ao fazer a avaliação a partir da intensidade do pixel, como a metodologia utilizada nesse trabalho, ao mesmo tempo que o detector classifica os RL da imagem, todas as porções de pixels que possuem a cor branca, que é representado por uma alta intensidade em níveis de cinza, serão marcados como RL também.

A tarefa de classificar apenas RL em uma imagem que apresenta pixels com a coloração branca ainda se mostra uma tarefa difícil. Uma nova metodologia deve ser




Figura 19 – Sequência de resultados obtidos utilizando imagem da Caneca original, detector manual, detector por LR e detector por LGCPP respectivamente.

adotada para a diferenciação desses pixels, onde a avaliação de intensidade não deve ser a única característica para diferenciá-los.

Uma outra limitação encontrada durante o processo de desenvolvimento consiste na demora em se realizar a detecção manual das imagens submetidas à detecção, pois a tarefa de marcar pixel a pixel de uma imagem utilizando um editor de imagens, além de ser um processo cansativo, também é um processo difícil, e dependendo da quantidade de RL espalhados pela cena, a marcação de alguns pixels que não são RL são feitos erroneamente. Outro fator que causa lentidão nesse processo se dá na utilização de 5 voluntários para a realização da detecção manual. Entretanto esse processo é necessário para validar os detectores testados.




Figura 20 – Sequência de resultados obtidos utilizando imagem do Bule original, detector manual, detector por LR e detector por LGCPP respectivamente.

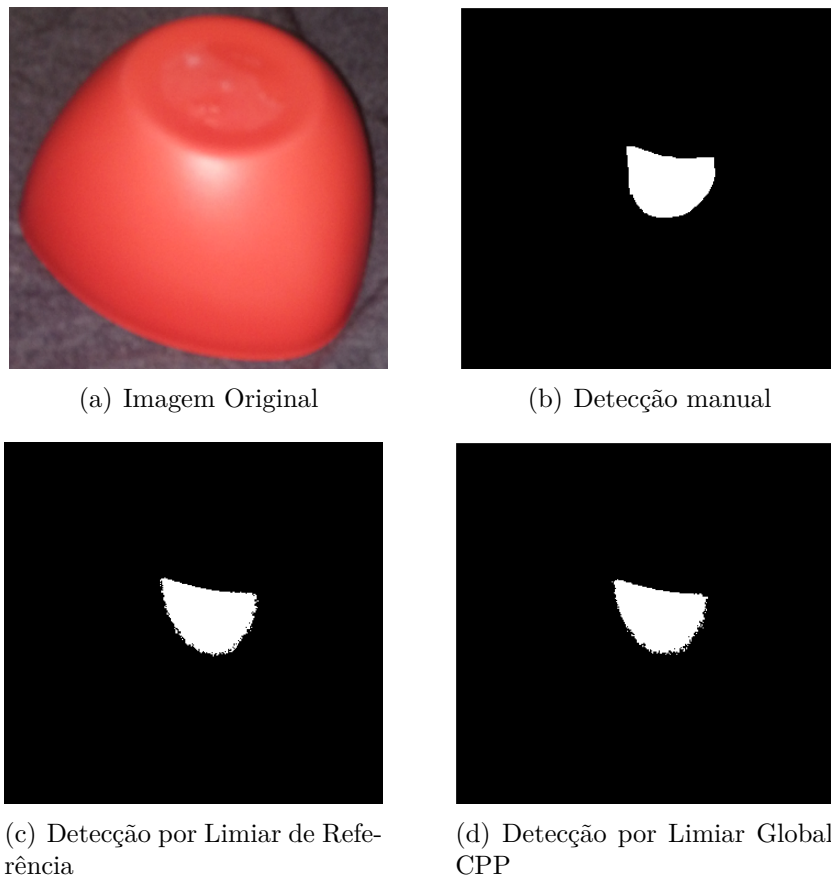


Figura 21 – Sequência de resultados obtidos utilizando imagem do Pote original, detector manual, detector por LR e detector por LGCPP respectivamente.

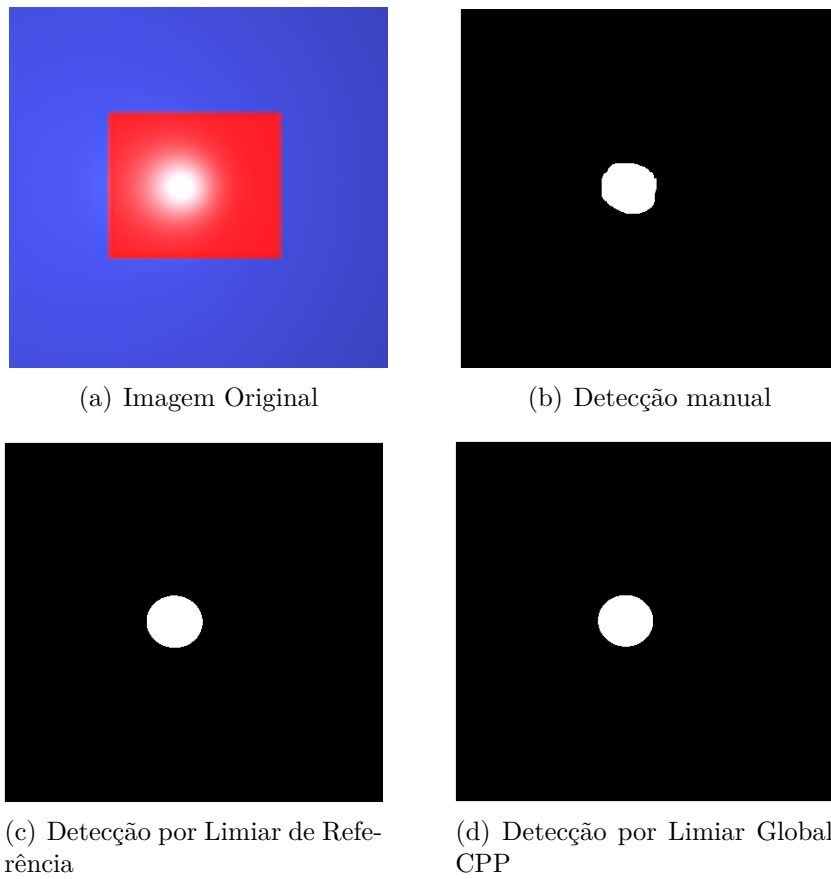


Figura 22 – Sequência de resultados obtidos utilizando a Imagem Sintética original, detector manual, detector por LR e detector por LGCPP respectivamente.

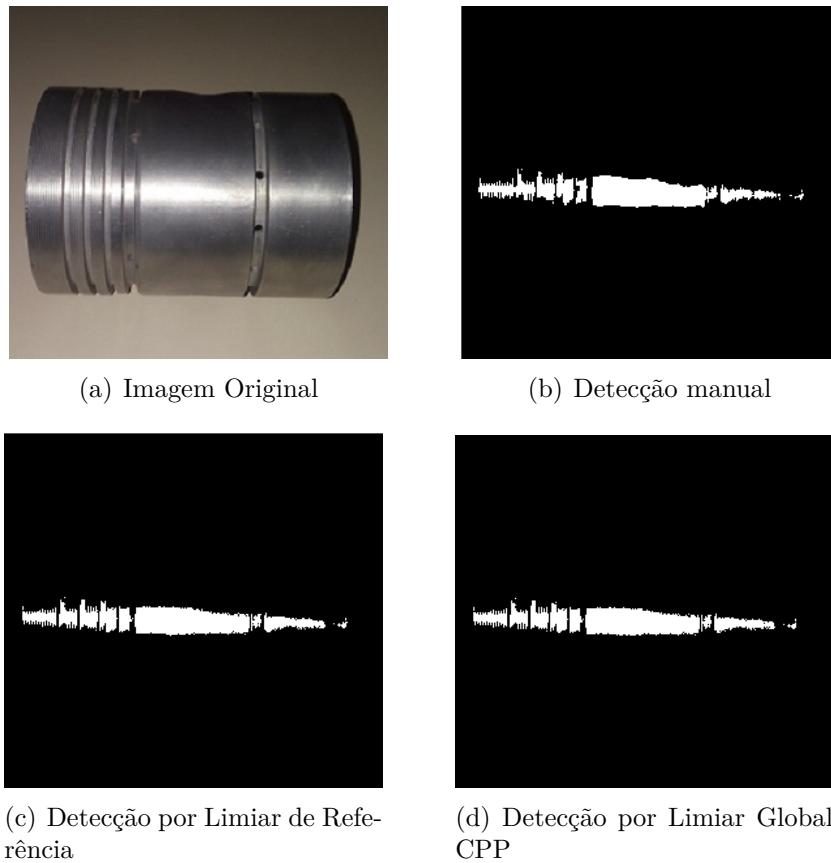


Figura 23 – Sequência de resultados obtidos utilizando imagem do Cilindro metálico original, detector manual, detector por LR e detector por LGCPP respectivamente.

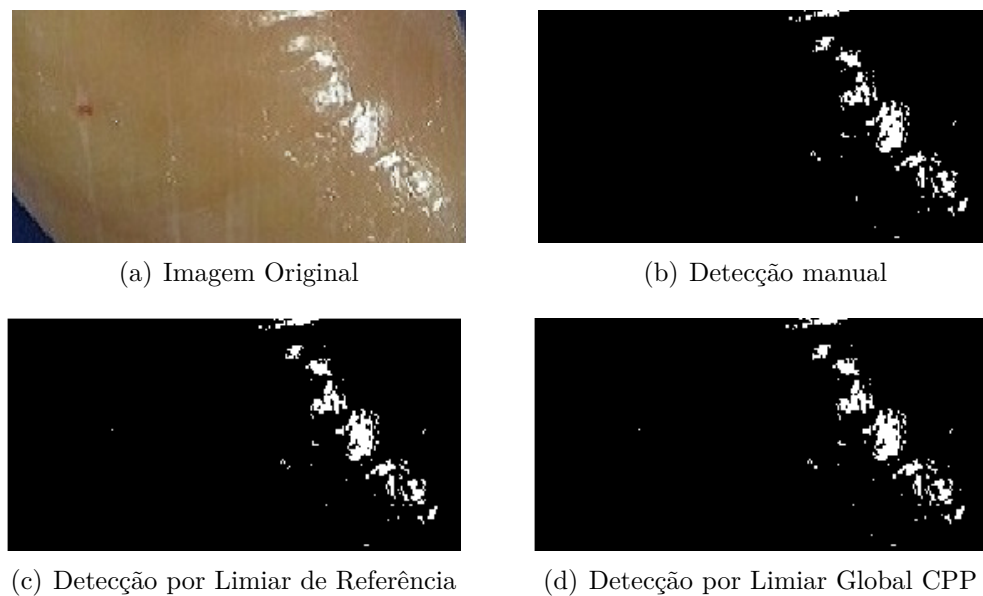


Figura 24 – Sequência de resultados obtidos utilizando imagem do Peito de frango original, detector manual, detector por LR e detector por LGCPP respectivamente.

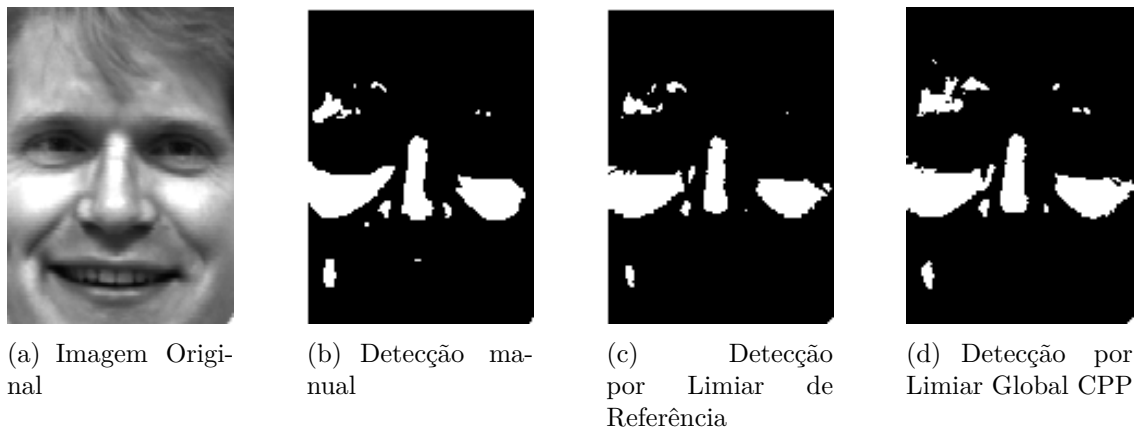


Figura 25 – Sequência de resultados obtidos utilizando imagem da Face 1 original, detector manual, detector por LR e detector por LGCPP respectivamente.

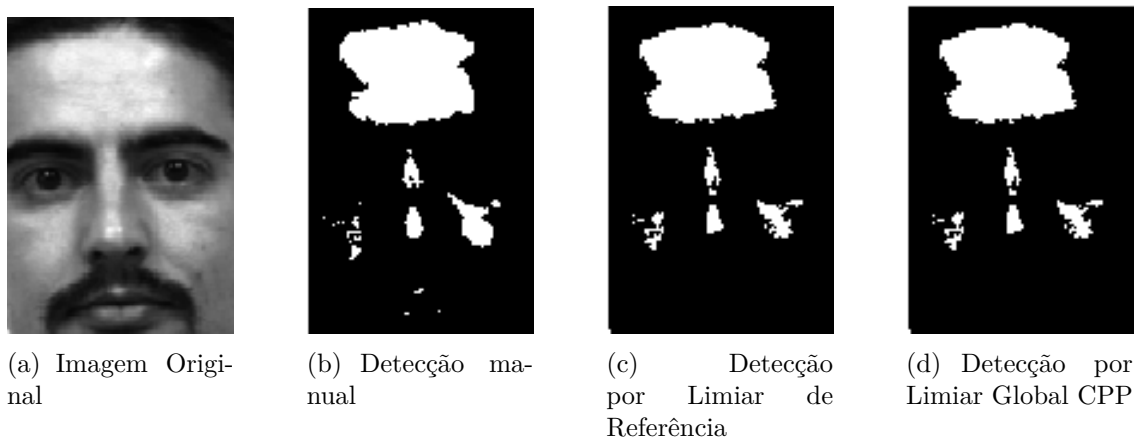


Figura 26 – Sequência de resultados obtidos utilizando imagem da Face 2 original, detector manual, detector por LR e detector por LGCPP respectivamente.




Figura 27 – Sequência de resultados obtidos utilizando imagem da Face 3 original, detector manual, detector por LR e detector por LGCPP respectivamente.

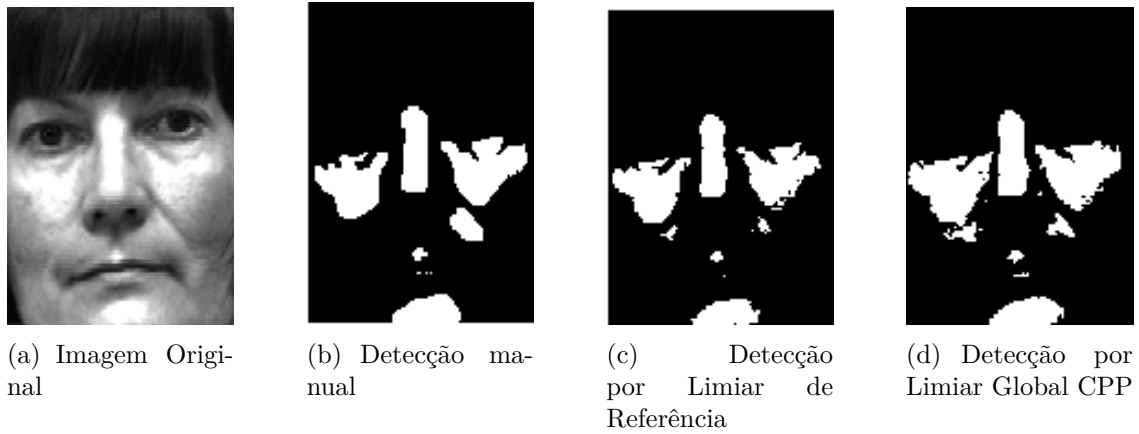


Figura 28 – Sequência de resultados obtidos utilizando imagem da Face 4 original, detector manual, detector por LR e detector por LGCPP respectivamente.

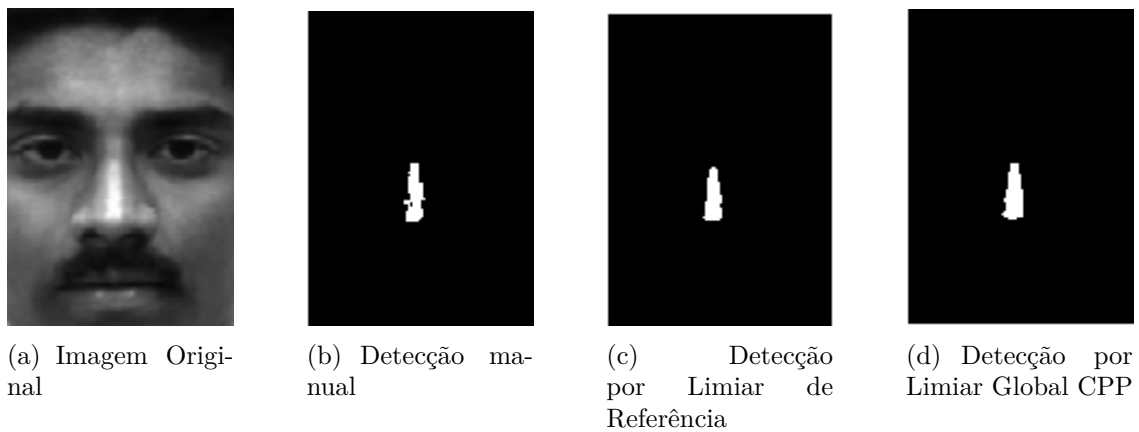


Figura 29 – Sequência de resultados obtidos utilizando imagem da Face 5 original, detector manual, detector por LR e detector por LGCPP respectivamente.

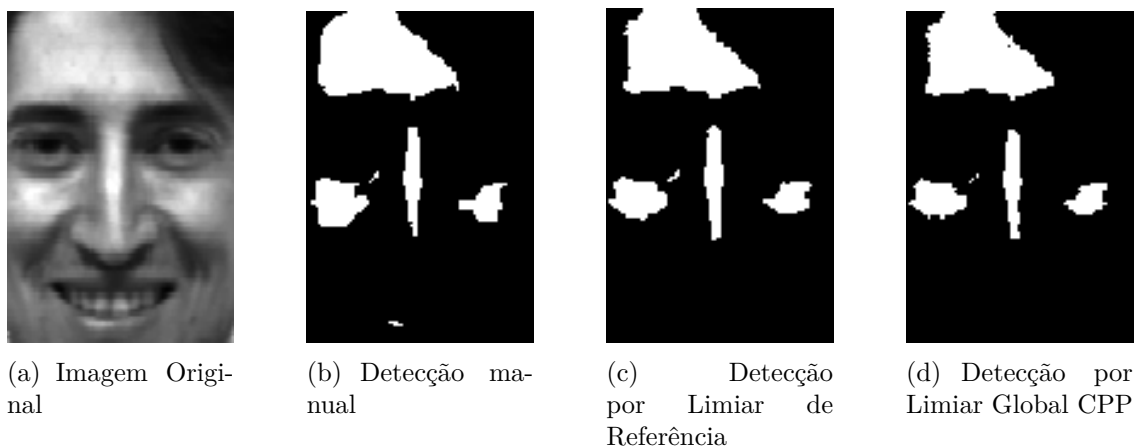


Figura 30 – Sequência de resultados obtidos utilizando imagem da Face 6 original, detector manual, detector por LR e detector por LGCPP respectivamente.

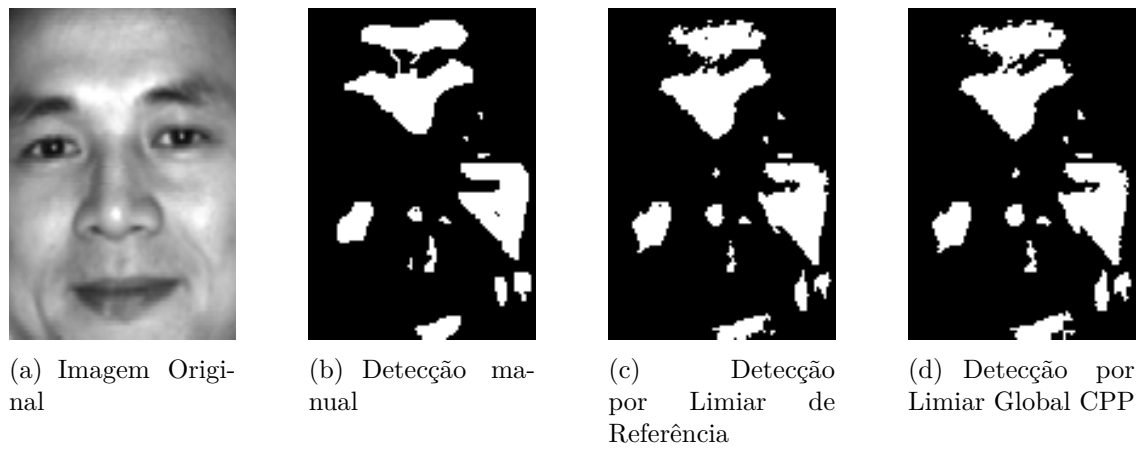


Figura 31 – Sequência de resultados obtidos utilizando imagem da Face 7 original, detector manual, detector por LR e detector por LGCPP respectivamente.




Figura 32 – Sequência de resultados obtidos utilizando imagem do Couro Vermelho original, detector manual, detector por LR e detector por LGCPP respectivamente.

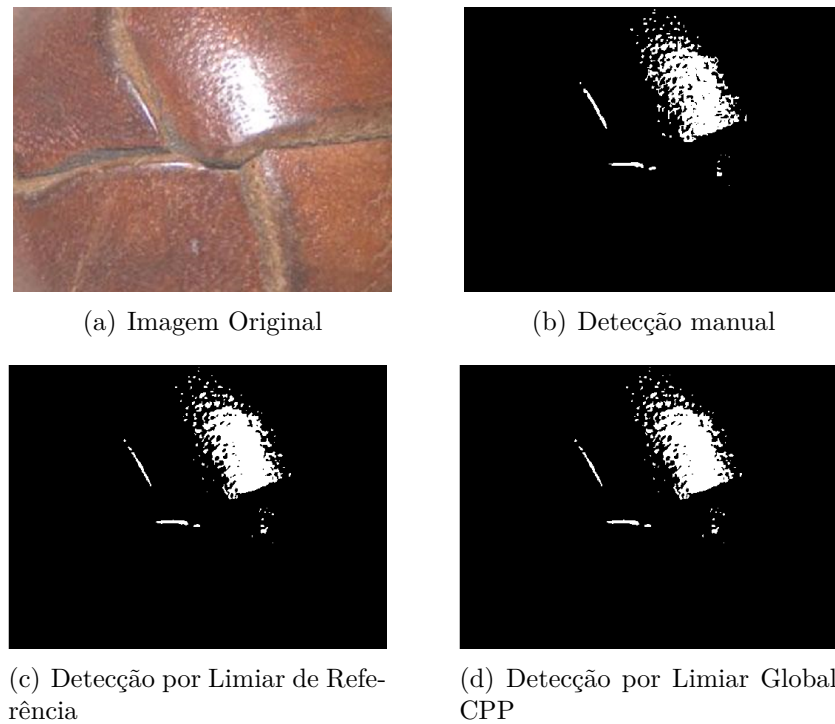


Figura 33 – Sequência de resultados obtidos utilizando imagem do Couro marrom original, detector manual, detector por LR e detector por LGCPP respectivamente.

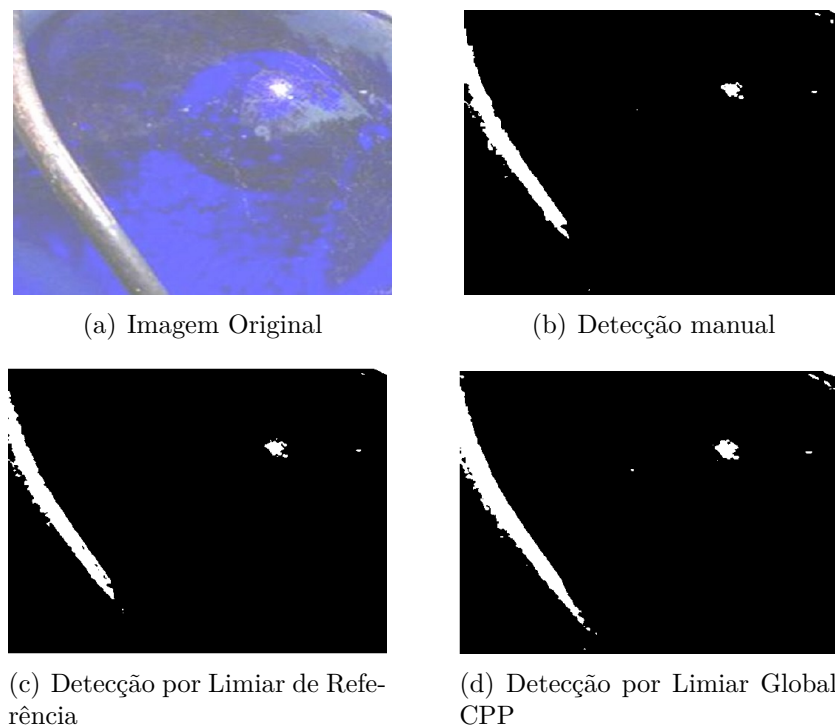


Figura 34 – Sequência de resultados obtidos utilizando imagem do Vidro 1 original, detector manual, detector por LR e detector por LGCPP respectivamente.

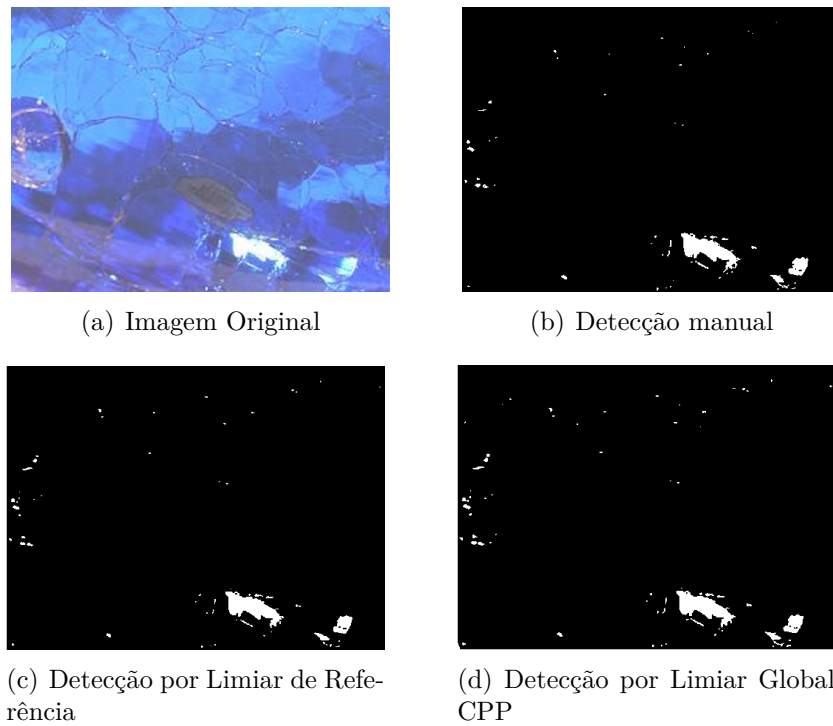


Figura 35 – Sequência de resultados obtidos utilizando imagem do Vidro 2 original, detector manual, detector por LR e detector por LGCPP respectivamente.




Figura 36 – Sequência de resultados obtidos utilizando imagem do Metal original, detector manual, detector por LR e detector por LGCPP respectivamente.

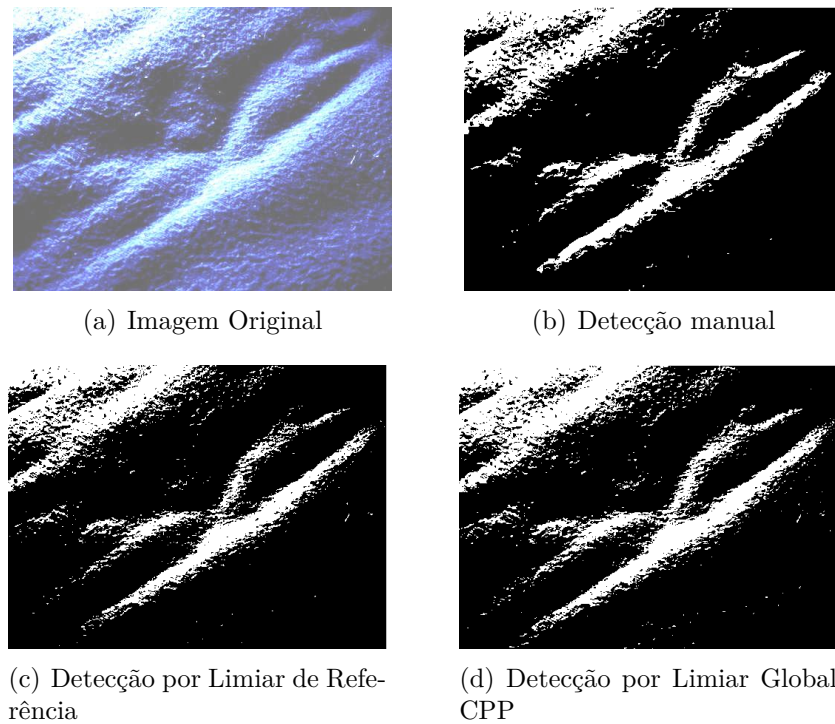


Figura 37 – Sequência de resultados obtidos utilizando imagem do Tecido original, detector manual, detector por LR e detector por LGCPP respectivamente.

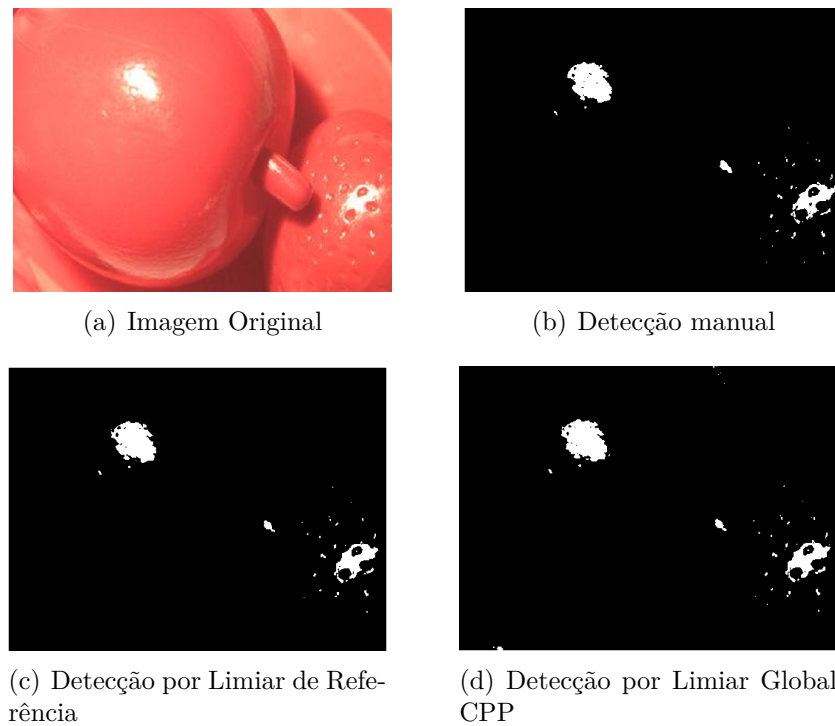


Figura 38 – Sequência de resultados obtidos utilizando imagem do Plástico original, detector manual, detector por LR e detector por LGCPP respectivamente.

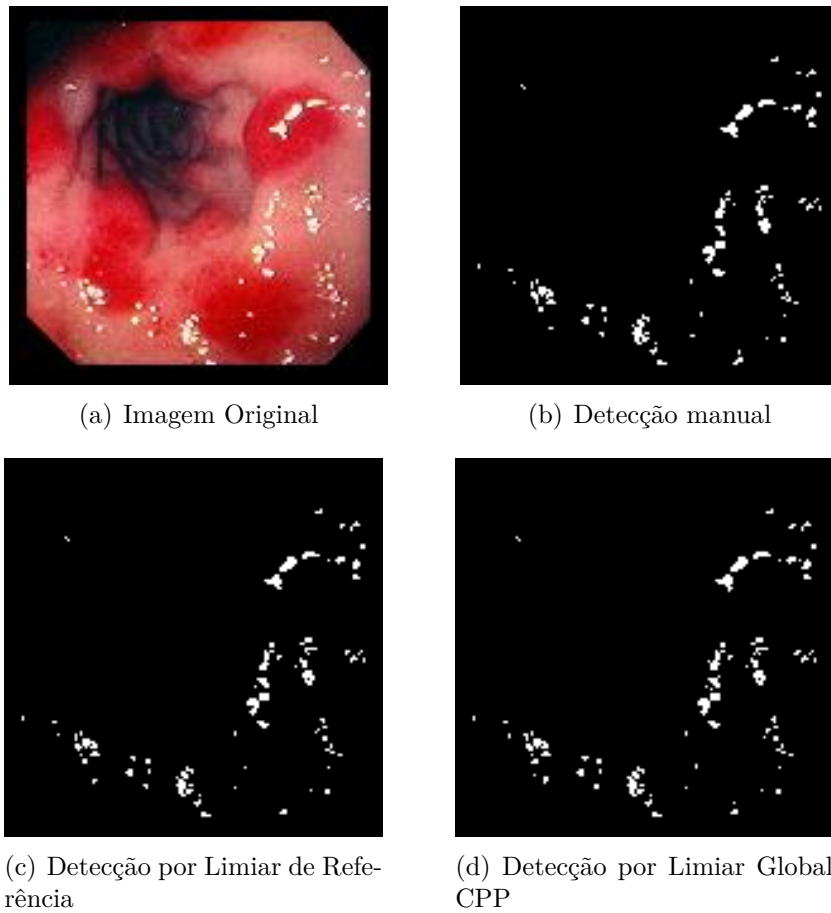


Figura 39 – Sequência de resultados obtidos utilizando da imagem Duodenite original, detector manual, detector por LR e detector por LGCPP respectivamente.

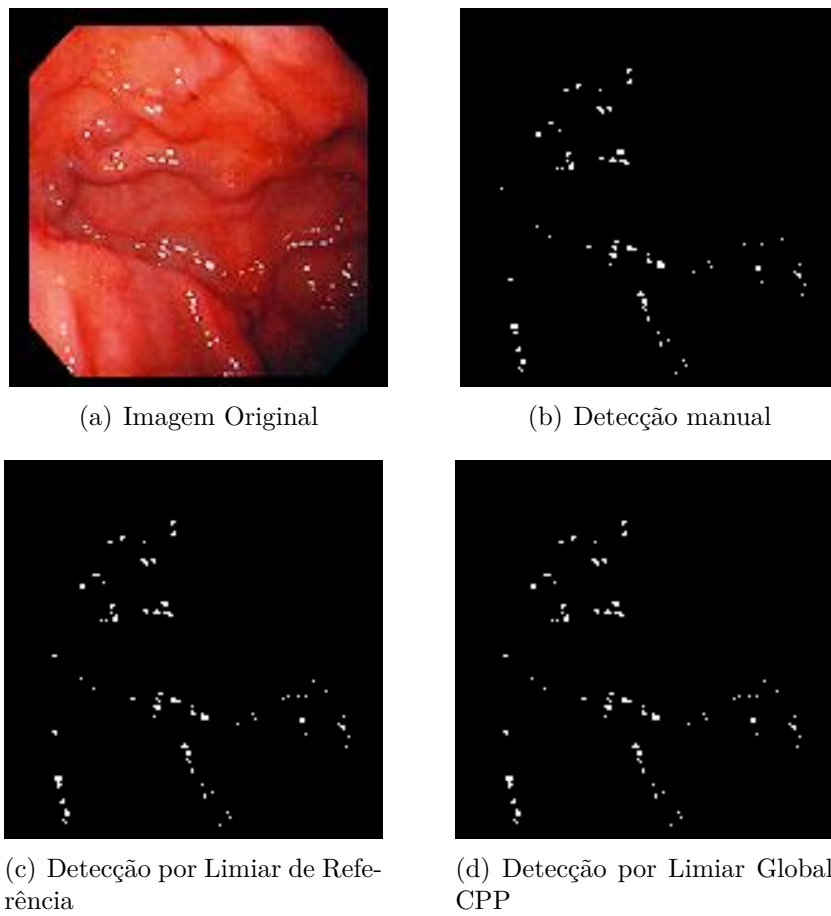


Figura 40 – Sequência de resultados obtidos utilizando da imagem Varizes gástricas original, detector manual, detector por LR e detector por LGCPP respectivamente.

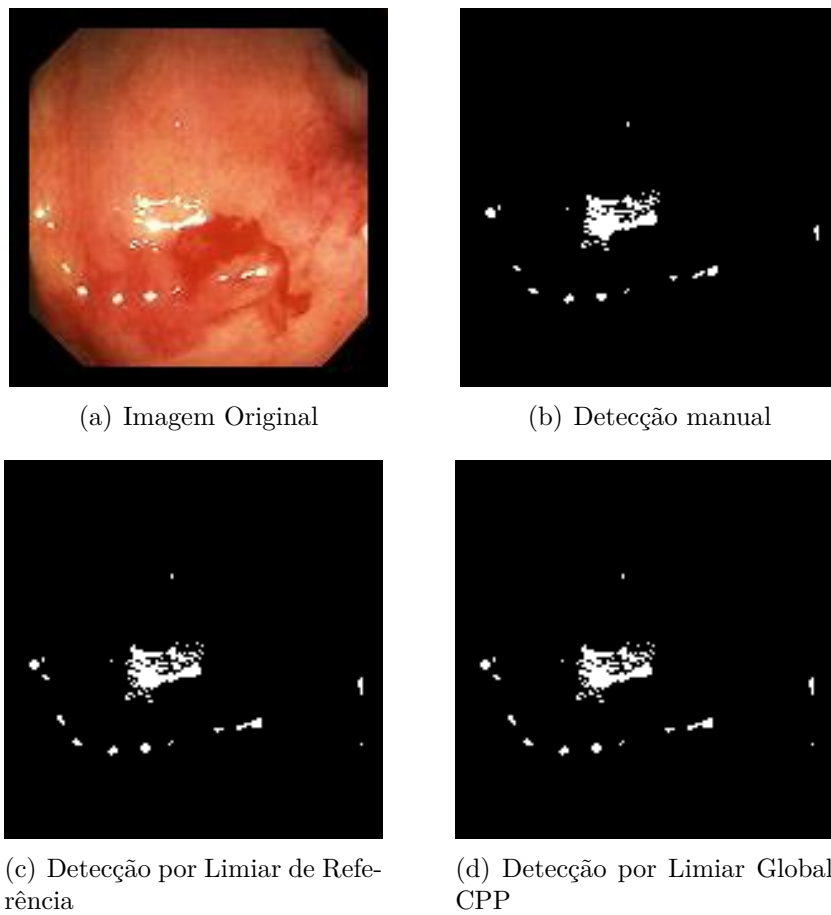


Figura 41 – Sequência de resultados obtidos utilizando da imagem Duodenite original, detector manual, detector por LR e detector por LGCPP respectivamente.

7 CONCLUSÃO

O pré-processamento proposto pelo trabalho para aumento do contraste de luminosidade dos pixels que possuem RL dos pixels normais demonstrou resultados satisfatórios em 2 dos 4 detectores propostos. Os detectores que apresentaram melhorias quando utilizados conjuntamente do pré-processamento foram o detector LG e PHA, sendo que em todos os casos as taxas de Exatidão em classificação dos RL sofreram um aumento significativo de 15,19% e 42,36%, respectivamente. Dessa forma, o detector LGCPP obteve maior destaque entre todos os detectores, atingindo uma média de Exatidão de 82.47%, mantendo estabilidade em todas as detecções feitas por ele entre os 3 grupos de imagens. Além disso, este detector apresentou resultados similares ao detector LR, que apresenta a melhor taxa de Exatidão possível de um detector obter, baseado nas detecções manuais dos RL nas imagens. Também foi constatado que a adaptação sugerida pelo autor em controlar a MinIP do detector LCT realmente apresentou resultados positivos, sendo que de todos resultados avaliados, sua taxa de Exatidão se manteve igual ao detector LCT ou até mesmo superior. Em casos onde a taxa de Exatidão do detector LCT atingiu 0% como resultado, a adaptação foi capaz de atingir resultados significantes, demonstrando que de fato, o MinIP possui variação para diferentes tipos de imagens e precisa ter seu valor controlado. Pretende-se como trabalhos futuros a aplicação do processo de restauração das regiões que sofreram ação dos RL utilizando a técnica de *inpainting*. Como o detector LGCPP apresentou os melhores resultados em detectar os RL nas imagens, ele será o detector que classificará as regiões a serem aplicadas à técnica de *inpainting*, para restauração dos pixels luminosos.

REFERÊNCIAS

- [1] TCHOULACK, S.; LANGLOIS, J. M. P.; CHERIET, F. A video stream processor for real-time detection and correction of specular reflections in endoscopic images. In: *2008 Joint 6th International IEEE Northeast Workshop on Circuits and Systems and TAISA Conference*. [S.l.: s.n.], 2008. p. 49–52.
- [2] YAO, R. et al. Specular reflection detection on gastroscopic images. In: *2010 4th International Conference on Bioinformatics and Biomedical Engineering*. [S.l.: s.n.], 2010. p. 1–4. ISSN 2151-7614.
- [3] HUANG, D.-Y. et al. Face recognition based on dual-tree complex wavelet transform under low illumination environments. In: *Proceedings of the 29th International Conference on Image and Vision Computing New Zealand*. New York, NY, USA: ACM, 2014. (IVCNZ '14), p. 253–258. ISBN 978-1-4503-3184-5. Disponível em: <<http://doi.acm.org/10.1145/2683405.2683450>>.
- [4] CHANG, R.-C.; TSENG, F.-C. Automatic detection and correction for glossy reflections in digital photograph. In: *2010 3rd IEEE International Conference on Ubi-Media Computing*. [S.l.: s.n.], 2010. p. 44–49.
- [5] MORGAND, A.; TAMAAZOUSTI, M. Generic and real-time detection of specular reflections in images. In: *2014 International Conference on Computer Vision Theory and Applications (VISAPP)*. [S.l.: s.n.], 2014. v. 1, p. 274–282.
- [6] KARAPETYAN, G.; SARUKHANYAN, H. Automatic detection and concealment of specular reflections for endoscopic images. In: *Ninth International Conference on Computer Science and Information Technologies Revised Selected Papers*. [S.l.: s.n.], 2013. p. 1–8.
- [7] SAINT-PIERRE, C.-A. et al. Detection and correction of specular reflections for automatic surgical tool segmentation in thoracoscopic images. *Mach. Vision Appl.*, Springer-Verlag New York, Inc., Secaucus, NJ, USA, v. 22, n. 1, p. 171–180, jan. 2011. ISSN 0932-8092. Disponível em: <<http://dx.doi.org/10.1007/s00138-007-0099-6>>.
- [8] VAZQUEZ, E. et al. Describing reflectances for color segmentation robust to shadows, highlights, and textures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 33, n. 5, p. 917–930, May 2011. ISSN 0162-8828.
- [9] JOHNSON, S. *Stephen Johnson on Digital Photography*. O'Reilly Media, Incorporated, 2006. (O'Reilly Series). ISBN 9780596523701. Disponível em: <<https://books.google.com.br/books?id=0UVRXzF91gcC>>.
- [10] RANI, L. S. U.; JAGAJOTHI, G.; SELVAN, P. T. Digital fuzzy random impulse noise reduction for grayscale images. In: *2016 International Conference on Emerging Trends in Engineering, Technology and Science (ICETETS)*. [S.l.: s.n.], 2016. p. 1–4.
- [11] ZVIRTES, L. Ferramentas de qualidade. p. 2, 2017.

- [12] SCHOENEMANN, T.; KAHL, F.; CREMERS, D. Curvature regularity for region-based image segmentation and inpainting: a linear programming relaxation. In: *2009 IEEE 12th International Conference on Computer Vision*. [S.l.: s.n.], 2009. p. 17–23. ISSN 1550-5499.
- [13] PINGTAN et al. Highlight removal by illumination-constrained inpainting. In: *Proceedings Ninth IEEE International Conference on Computer Vision*. [S.l.: s.n.], 2003. p. 164–169 vol.1.
- [14] KAWAI, N. et al. AR marker hiding based on image inpainting and reflection of illumination changes. In: *2012 IEEE International Symposium on Mixed and Augmented Reality (ISMAR)*. [S.l.: s.n.], 2012. p. 293–294.
- [15] GUO, J. J. et al. A specular reflection suppression method for endoscopic images. In: *2016 IEEE Second International Conference on Multimedia Big Data (BigMM)*. [S.l.: s.n.], 2016. p. 125–128.
- [16] GONZALES, R. E. W. R. C. *Digital image processing (in Portuguese)*. [S.l.]: Pearson, 2011. 259–274 p.
- [17] BELHUMEUR, J. H. P. N.; KRIEGMAN, D. J. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Trans. on PAMI*, v. 19, p. 711–720, July 1997.
- [18] SHARAN, L.; ROSENHOLTZ, R.; ADELSON, E. H. Accuracy and speed of material categorization in real-world images. *Journal of Vision*, v. 14, n. 10, 2014.
- [19] MARTIN, D. M. *Atlas of Gastrointestinal Endoscopy*. 1996. Base obtida em: <http://www.endoatlas.com/atlas_1.html>.
- [20] SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, v. 45, n. 4, p. 427 – 437, 2009. ISSN 0306-4573. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0306457309000259>>.
- [21] BARNSTON, A. G. Correspondence among the correlation, rmse, and heidke forecast verification measures; refinement of the heidke score. *Weather and Forecasting*, v. 7, n. 4, p. 699–709, 1992. Disponível em: <[https://doi.org/10.1175/1520-0434\(1992\)007<0699:CATCRA>2.0.CO;2](https://doi.org/10.1175/1520-0434(1992)007<0699:CATCRA>2.0.CO;2)>.
- [22] SILVA, R. et al. Automatic luminous reflections detector using global threshold with increased luminosity contrast in images. *Journal of Electronic Imaging*, v. 27, p. 27 – 27 – 15, 2018. Disponível em: <<https://doi.org/10.1117/1.JEI.27.1.011009>>.

TRABALHOS PUBLICADOS PELO AUTOR

Trabalhos publicados pelo autor durante o programa.

1. Ricardo Petri Silva, Gustavo Taiji Naozuka, Saulo Martiello Mastelini, Alana Salvany Felinto, **Automatic luminous reflections detector using Global Threshold with increased luminosity contrast in images**, Journal of Electronic Imaging, v. 27, p. 15 – 27, 2018. (Qualis CC 2018, A2).