
Avaliação da Capacidade de Retenção de Água em Amostras de Carne Suína

Renan Gomes de Andrade



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Uberlândia
2019

Renan Gomes de Andrade

**Avaliação da Capacidade de Retenção de Água
em Amostras de Carne Suína**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Ciência da Computação

Orientador: André Ricardo Backes

Uberlândia
2019

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

A553a Andrade, Renan Gomes de, 1992-
2019 Avaliação da capacidade de retenção de água em amostras de carne
suína [recurso eletrônico] / Renan Gomes de Andrade. - 2019.

Orientador: André Ricardo Backes.
Dissertação (mestrado) - Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Ciência da Computação.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2019.76>
Inclui bibliografia.
Inclui ilustrações.

1. Computação. 2. Processamento de imagens - Técnicas digitais. 3.
Carne de porco - Qualidade. 4. Segmentação de imagem. I. Backes,
André Ricardo (Orient.). II. Universidade Federal de Uberlândia.
Programa de Pós-Graduação em Ciência da Computação. III. Título.

CDU: 681.3

Rejâne Maria da Silva – CRB6/1925



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

ATA DE DEFESA

Programa de Pós-Graduação em:	Ciência da Computação			
Defesa de:	Dissertação de Mestrado Acadêmico, 06/2019, PPGCO			
Data:	17 de julho de 2019	Hora de início:	13h10min	Hora de encerramento:
Matrícula do Discente:	11722CCP010			
Nome do Discente:	Renan Gomes de Andrade			
Título do Trabalho:	Avaliação da Capacidade de Retenção de Água em Amostras de Carne Suína			
Área de concentração:	Ciência da Computação			
Linha de pesquisa:	Ciência de Dados			
Projeto de Pesquisa de vinculação:	-			

Reuniu-se na sala 1B132, Bloco 1B, Campus Santa Mônica, da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciência da Computação, assim composta: Professores Doutores: Marcelo Zanchetta do Nascimento - FACOM/UFU, Dalcimar Casanova - DAINF/UTFPR, e André Ricardo Backes - FACOM/UFU, orientador do candidato.

Ressalta-se que o Prof. Dr. Dalcimar Casanova participou da defesa por meio de videoconferência desde a cidade de Pato Branco -PR. Os outros membros da banca e o aluno participaram in loco.

Iniciando os trabalhos o presidente da mesa, Prof. Dr. André Ricardo Backes, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **André Ricardo Backes, Professor(a) do Magistério Superior**, em 18/07/2019, às 11:31, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcelo Zanchetta do Nascimento, Professor(a) do Magistério Superior**, em 18/07/2019, às 16:24, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Dalcimar Casanova, Usuário Externo**, em 08/08/2019, às 16:20, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site
https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1396700** e o código CRC **E34DEF99**.

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Os abaixo assinados, por meio deste, certificam que leram e recomendam para a Faculdade de Computação a aceitação da dissertação intitulada **”Avaliação da Capacidade de Retenção de Água em Amostras de Carne Suína”** por **Renan Gomes de Andrade** como parte dos requisitos exigidos para a obtenção do título de **Mestre em Ciência da Computação**.

Uberlândia, ____ de ____ de ____

Orientador: _____

Prof. Dr. André Ricardo Backes
Universidade Federal de Uberlândia

Banca Examinadora:

Prof. Dr. Marcelo Zanchetta do Nascimento
Universidade Federal de Uberlândia

Prof. Dr. Dalcimar Casanova
Universidade Tecnológica Federal do Paraná

Dedico este trabalho a todos que de alguma maneira me ajudaram a concluir mais essa etapa da minha vida.

Agradecimentos

Agradeço primeiramente a Deus, pois sem ele esse momento não seria possível.

À Faculdade de Computação da Universidade Federal de Uberlândia, pela disponibilização do curso de Mestrado.

Às organizações de fomento de pesquisa do Brasil, como: CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), FAPEMIG (Fundação de Amparo à Pesquisa do Estado de Minas Gerais) e em especial à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), pela concessão da bolsa de Mestrado.

Ao meu orientador André Ricardo Backes, pela oportunidade de me orientar durante a realização deste trabalho. Pelos seus ensinamentos, correções e incentivos. Pela sua disposição, paciência e entusiasmo.

À Isaura Maria Ferreira do Programa de Pós-Graduação em Ciências Veterinárias da Universidade Federal de Uberlândia, pela disponibilização das imagens utilizadas durante este trabalho.

A todos os professores, servidores e colegas de pós-graduação da Universidade Federal de Uberlândia, dos quais pude conviver durante todo esse período.

À minha família, por sempre me apoiar em todas as fases da minha vida.

À Bárbara Priscylla, pelo seu apoio, incentivo e paciência durante os momentos mais difíceis.

Resumo

A carne suína é uma das fontes de proteína animal mais consumidas no Brasil e no mundo. Diante disso, é extremamente importante que a carne oferecida aos consumidores passe por um rigoroso processo de controle de qualidade. Normalmente, a qualidade da carne suína está associada a medidas de características desejadas e valorizadas pelo consumidor. Dentre as várias características analisadas para se obter um produto de alta qualidade, a Capacidade de Retenção de Água (CRA) é uma das mais utilizadas. Os níveis de concentração de água na carne suína estão relacionados diretamente com o seu aspecto visual, maciez, suculência, firmeza e rendimento durante o preparo. Normalmente, a CRA é quantificada pelo método de compressão, que consiste em estimar a quantidade de água de uma amostra ao medir o volume de suco liberado após a sua compressão. No entanto, esse processo é realizado manualmente por especialistas, o que faz dela uma operação demorada, imprecisa, variável, cara e vulnerável a falhas e ao cansaço humano. Tendo em vista a necessidade de automatização desse processo e a escassez de pesquisas que utilizam técnicas de processamento digital de imagens para segmentar e quantificar CRA, foi desenvolvido um método de segmentação automática capaz de quantificar as CRAs de amostras de carnes suínas. A eficiência do método proposto é avaliada a partir da realização de experimentos onde a segmentação das amostras e a precisão das CRAs extraídas são analisadas. Em ambos os experimentos, o método proposto obteve resultados satisfatórios. Pelo menos 93% de todas as imagens foram segmentadas com sucesso e os valores das CRAs extraídos por especialistas e pelo método proposto ficaram muito próximos. Sendo assim, este trabalho poderá auxiliar profissionais da área de controle de qualidade de alimentos a realizar uma quantificação de CRA mais eficiente, prática e com menor custo.

Palavras-chave: Capacidade de Retenção de Água (CRA). Qualidade da Carne Suína. Processamento Digital de Imagens (PDI). Segmentação.

Abstract

Pork is one of the protein source most consumed in Brazil and in the world. Therefore, it is extremely important that the meat offered to consumers pass for a strict process to control of quality. Usually, pork's quality is associated with some features desired and valued by consumers. Among the many attributes analyzed to obtain a high quality product, Water Holding Capacity (WHC) is one of the most used. The levels of water concentration in pork are directly related to its visual appearance, softness, juiciness, firmness and yield during preparation. WHC is usually quantified by the compression method, which consists of estimating the amount of water in a sample by measuring the volume of juice released after its compression. However, this process is done manually by experts, what makes this a slow, imprecise, variable and expensive operation, vulnerable to failure and human fatigue. In view of the need to automation this process and the scarcity of research using digital image processing techniques to segment and quantify WHC, we developed an automatic segmentation method capable of quantifying the WHCs of pork samples. The efficiency of the proposed method is evaluated by performing experiments where the segmentation of the samples and the accuracy of the extracted WHCs are analyzed. In both experiments, the proposed method obtained satisfactory results. About 93% of all images were successfully segmented and the values of the WHCs extracted by experts and the proposed method were very close. Therefore, this work may help professionals in the area of food control to perform a more efficient, practical and cheaper WHC quantification.

Keywords: Water Holding Capacity (WHC). Quality of Pork. Digital Image Processing. Segmentation.

Lista de ilustrações

Figura 1 – Exemplo de amostras com suas áreas sobrepostas após a aplicação do método de compressão..	24
Figura 2 – Representação de funções básicas de transformações de intensidade, onde L corresponde ao número máximo de intensidade, r o valor de entrada e s o resultado..	28
Figura 3 – Exemplo de um histograma, onde o sentido horizontal representa o valor da intensidade e o vertical à quantidade de pixels..	29
Figura 4 – Representação e localização de uma cor específica através do cubo RGB, sendo (a) a visão externa do cubo, (b) a visão interna e (c) a representação de uma cor específica..	31
Figura 5 – Representação gráfica do funcionamento dos atributos do sistema HSV.	32
Figura 6 – Exemplo de dilatação, onde (a) representa o elemento A, (b) o elemento estruturante e (c) o resultado..	33
Figura 7 – Exemplo de erosão, sendo (a) o elemento A, (b) o elemento estruturante e (c) o resultado..	34
Figura 8 – Exemplo de abertura, onde (a) representa a imagem original, (b) a imagem após a erosão e (c) o resultado após a dilatação..	35
Figura 9 – Exemplo de fechamento, onde (a) representa a imagem original, (b) a imagem após a dilatação e (c) o resultado após a erosão..	35
Figura 10 – Representação dos conceitos vizinhança, onde (a) corresponde a 4-vizinhança, (b) vizinhança diagonal e (c) 8-vizinhança..	36
Figura 11 – Exemplos de conectividade em uma imagem binária, onde em (a) a coleção de pixels S representa um conjunto conexo e (b) os grupos de pixels S e R correspondem a componentes conexos..	37
Figura 12 – Representação do processo de rotulação de componentes conexos, onde (a) representa uma imagem binária, na qual os pixels do fundo correspondem a 0 e os objetos equivalem a 1 e (b) a rotulação e destaque dos dois componentes conexos presentes na imagem..	37

Figura 13 – Representação da técnica de preenchimento de regiões e suas iterações, onde (a) corresponde ao conjunto de pixels do objeto A , (b) o complemento de A , (c) o elemento estruturante, (d) marcação do pixel inicial X_0 , (e), (f) e (g) são representações de diferentes etapas após operações de dilatação (X_1 , X_2 e X_8 respectivamente) e (h) $X_8 \cup A$ representando a união do objeto original mais a sua área interna preenchida.	38
Figura 14 – Representação da técnica de esqueletização, onde (a) corresponde ao objeto original, (b) esqueleto por <i>MAT</i> e (c) esqueletização por <i>Disco Máximo</i>	39
Figura 15 – Representação do particionamento de três classes pelo método <i>K-means</i> , onde em (a) é possível observar a geração dos centróides representados pelos círculos maiores e os pontos menores correspondem aos elementos do conjunto de dados, (b) cada ponto é atribuído ao grupo de centróide mais próximo e em (c) é alcançado o estado final com os centróides já recalculados.	41
Figura 16 – Ilustração de um grafo com arestas ponderadas.	42
Figura 17 – Representação do menor caminho entre o vértice inicial s e o terminal t de um grafo ponderado, onde em cada aresta é possível observar o seu respectivo custo de deslocamento e cada vértice é rotulado com a menor distância entre s e ele mesmo.	43
Figura 18 – Exemplo de limiarização entre duas classes de objetos em um histograma.	44
Figura 19 – Etapas do método de compressão. A letra (a) representa a primeira etapa, onde são colocadas as amostras de carne sobre os filtros de papel, em (b) são adicionadas as placas de acrílico entre as amostras, em (c) as anilhas são colocadas em cima do material e por último, (d) representa a análise e quantificação dos resultados.	46
Figura 20 – Representação do sistema de análise de imagens de peito de frango via câmera digital.	47
Figura 21 – Representação do sistema de análise de imagens hiperespectrais de carne bovina.	48
Figura 22 – Representação do mapa de distribuição de CRA em amostras de carnes bovinas via imagens hiperespectrais. Abaixo de cada uma delas é possível observar a média dos seus respectivos níveis de CRA, onde tons avermelhados correspondem a maiores quantidades de água retida.	49
Figura 23 – Etapas do método proposto de avaliação da capacidade de retenção de água em amostras de carne suína.	52
Figura 24 – Representação das primeiras etapas de preparação das imagens, onde (a) representa a imagem original e (b) a mesma rotacionada em 90° e convertida para <i>PNG</i>	53

Figura 25 – Exemplo de extração da máscara de recorte de fundo, onde (a) representa a imagem original e (b) a máscara utilizada como referência para extração do fundo..	54
Figura 26 – Representação do processo de recorte, onde (a) corresponde à máscara original, (b) gráfico das médias de intensidade das colunas, (c) a máscara após o recorte das colunas, (d) gráfico das médias de intensidade das linhas e (e) o resultado da máscara após o recorte das linhas e colunas..	55
Figura 27 – Representação do resultado da aplicação da técnica de recorte de fundo, onde (a) representa a imagem original com a região de interesse destacada e (b) o resultado final da técnica de recorte de fundo..	56
Figura 28 – Representação da evolução dos valores de intensidade em uma determinada imagem após a aplicação da transformação logarítmica com diferentes fatores de multiplicação. Em (a) é realizada uma comparação entre as intensidades originais e as mesmas após a transformação logarítmica e (b) corresponde aos valores dos diferentes fatores de multiplicação utilizados na imagem..	57
Figura 29 – Histogramas representando o antes e depois das alterações de brilho, onde (a) representa o histograma da imagem original e (b) o histograma após as aplicações das técnicas de deslocamento da média, expansão de brilho e transformação logarítmica..	58
Figura 30 – Exemplos da aplicação das técnicas de correção de brilho, onde (a) e (c) são imagens originais com regiões de diferentes intensidades de brilho e (b) e (d) os seus respectivos resultados após a correção..	59
Figura 31 – Representação da aplicação da técnica de correção dos canais <i>RGB</i> , onde (a) corresponde a uma imagem com o canal <i>G</i> desbalanceado e (b) o resultado após a correção do canal <i>G</i>	60
Figura 32 – Representação da aplicação da técnica de realce de contraste, onde (a) corresponde a uma imagem original e (b) o resultado após o realce do amarelo..	61
Figura 33 – Representação de algumas das etapas da segmentação da área externa, onde (a) corresponde à imagem original após o realce do amarelo, (b) a mesma após a limiarização, (c) a operação de fechamento e (d) o preenchimento de regiões..	63
Figura 34 – Representação do processo de eliminação de falsos positivos, onde (a) representa a imagem original após o realce do amarelo, (b) a mesma após a limiarização, (c) a eliminação de falsos positivos pela operação de componentes conexos e (d) o resultado após a aplicação das margens laterais..	64

Figura 35 – Representação da execução do algoritmo de agrupamento <i>K-means</i> , onde (a) representa a imagem original após a correção de iluminação, (b) a mesma após a etapa de limiarização, (c) o maior componente conexo da imagem e (d) o resultado após a segmentação pelo <i>K-means</i> . ⁶⁵	65
Figura 36 – Comparação do processo de esqueletização, onde (a) representa uma amostra segmentada e (b) o seu esqueleto.	66
Figura 37 – Representação de alguns pontos de um determinado esqueleto, onde a marcação em vermelho representa um ponto extremo, em azul uma junção e em verde são pontos de linhas.	67
Figura 38 – Representação do processo de preenchimento e detecção de pontos extremos, onde (a) representa a segmentação incompleta de uma amostra, (b) o seu esqueleto, (c) a mesma imagem ampliada com a ligação dos pontos extremos em vermelho e (d) o resultado da técnica.	68
Figura 39 – Representação do processo de recorte das áreas externas, onde (a) corresponde a imagem original e (b) o resultado da segmentação.	69
Figura 40 – Representação das marcações feitas por canetas de diferentes cores, onde (a) representa a cor azul, (b) verde, (c) vermelha e (d) preta.	70
Figura 41 – Representação de algumas das etapas do processo de segmentação da área interna, onde (a) é a imagem original segmentada, (b) a mesma após a limiarização, (c) a remoção dos pequenos falsos positivos e aplicação da operação de fechamento e (d) o resultado após o preenchimento das regiões.	71
Figura 42 – Representação de amostras contendo falhas nas suas marcações.	72
Figura 43 – Representação do processo de preenchimento e detecção de pontos extremos, onde (a) representa a segmentação incompleta das áreas demarcadas, (b) os esqueletos dos objetos de interesse, (c) a mesma ampliada contendo em destaque as ligações realizadas entre as extremidades dos objetos e (d) o resultado da técnica.	73
Figura 44 – Representação do processo de segmentação onde à esquerda está a imagem original e à direita a mesma com as suas regiões identificadas. . . .	74
Figura 45 – Resultado da etapa de preparação aplicada no subconjunto de imagens selecionadas do dataset.	76
Figura 46 – Resultado da etapa de correção da iluminação aplicada no subconjunto de imagens selecionadas do dataset.	77
Figura 47 – Imagens do subconjunto que permaneceram com algumas irregularidades, onde à esquerda estão as originais e à direita o resultado da correção.	77

Figura 48 – Resultados da etapa de segmentação da área externa ocorridos com êxito, onde à esquerda se encontram as imagens após o realce do amarelo e à direita o resultado da segmentação. Em (a) e (b) são apresentados os resultados de imagens com diferentes tons de iluminação e intensidades de amarelo. Já em (c) é apresentado um caso no qual foi necessário aplicar o <i>K-means</i> , onde um terceiro tom foi aplicado para diferenciar visualmente as amostras.	78
Figura 49 – Resultados da etapa de segmentação da área externa que não puderam ser completamente segmentados, onde à esquerda se encontram as imagem após o realce do amarelo e à direita o resultado da segmentação com os erros destacados em vermelho.	79
Figura 50 – Resultado da etapa de segmentação da área externa onde as duas amostras não foram segmentadas de forma correta, onde à esquerda se encontra a imagem após o realce do amarelo e à direita o resultado da segmentação.	79
Figura 51 – Resultados da etapa de segmentação da área interna ocorridos com êxito, onde à esquerda estão as imagens originais e à direita os resultados da segmentação.	80
Figura 52 – Resultados da etapa de segmentação da área interna que não puderam ser corretamente segmentados, onde (a) representa o resultado de uma segmentação da área interna influenciada pela externa e (b) a segmentação de uma amostra com falhas nas suas marcações.	81
Figura 53 – Comparação entre os resultados obtidos pelo método proposto e pelo especialista, onde em (a) são analisadas apenas as CRAs das amostras localizadas na parte esquerda de cada imagem, em (b) são analisadas as CRAs das segundas amostras localizadas na parte direita e (c) corresponde à média entre as CRAs das duas amostras de cada imagem.	84
Figura 54 – Regressão linear da relação entre as médias de CRAs obtidas pelo método proposto e pelo especialista.	85

Lista de tabelas

Tabela 1 – Informações obtidas via análise visual sobre o aproveitamento das segmentações das regiões externas e internas das 1330 amostras (duas por imagem) do dataset. Na terceira linha são apresentadas as informações do aproveitamento da segmentação da área interna e externa de uma mesma amostra..	82
Tabela 2 – Informações das amostras obtidas a partir da aplicação do método proposto no grupo de imagens selecionadas, onde <i>A</i> corresponde a amostra do lado esquerdo e <i>B</i> a do lado direito da imagem..	83
Tabela 3 – Informações das amostras do grupo de imagens selecionadas obtidas manualmente por um profissional especialista, onde <i>A</i> corresponde a amostra do lado esquerdo e <i>B</i> a do lado direito da imagem..	83

Sumário

1	INTRODUÇÃO.	23
1.1	Motivação	25
1.2	Objetivos e Desafios da Pesquisa	25
1.2.1	Objetivos Específicos.	25
1.3	Organização da Dissertação	26
2	FUNDAMENTAÇÃO TEÓRICA.	27
2.1	Realce de imagens	27
2.1.1	Correção de Brilho.	27
2.1.2	Contraste.	28
2.2	Modelo de Cores	31
2.3	Operações morfológicas	33
2.3.1	Dilatação.	33
2.3.2	Erosão.	34
2.3.3	Abertura e Fechamento.	35
2.3.4	Componentes Conexos.	36
2.3.5	Preenchimento de Regiões (buracos).	37
2.3.6	Esqueletização.	39
2.4	Algoritmo de Agrupamento K-means	40
2.5	Cálculo do Menor Caminho	41
2.6	Segmentação	43
2.6.1	Limiarização.	44
2.7	Trabalhos Relacionados	45
2.7.1	Conclusão.	49
3	METODOLOGIA.	51
3.1	Descrição Geral	51
3.2	Preparação das Imagens	52

3.3	Correção da Iluminação	56
3.4	Segmentação da Área Externa	60
3.5	Segmentação da Área Interna	68
3.6	Cálculo das áreas e da CRA	73
4	EXPERIMENTOS E ANÁLISE DOS RESULTADOS.	75
4.1	Dataset	75
4.2	Análise Experimental	75
4.3	Avaliação dos Resultados	81
4.3.1	Análise da Segmentação.	82
4.3.2	Análise da CRA.	82
5	CONCLUSÃO.	87
5.1	Principais Contribuições	88
5.2	Trabalhos Futuros	88
	REFERÊNCIAS.	89

CAPÍTULO 1

Introdução

Atualmente a carne suína é uma das fontes de proteína animal mais consumidas no mundo, representando quase 40% de todo consumo e produção (FAO,2018). O Brasil é o quinto país onde mais se consome carne suína e o quarto maior produtor e exportador. Diante disso, o controle da qualidade da carne que chega até o consumidor é extremamente importante, tanto em aspectos como sabor, aparência e higiene, quanto para a sua comercialização. Os consumidores estão cada vez mais exigentes quando o assunto é a qualidade do produto que eles irão consumir. Uma das grandes preocupações da indústria alimentícia é justamente com essa qualidade. Estima-se que somente nos Estados Unidos, cerca de U\$ 100 milhões são perdidos todo o ano com a não comercialização de carnes suínas inadequadas (ALVES,2011).

A qualidade da carne suína está associada a medidas de características desejadas e valorizadas pelo consumidor. Algumas delas são: aparência, cor, sabor, textura, suculência, capacidade de retenção de água, quantidade de gordura, pH, entre outras. Muitos fatores como genética, nutrição e condições pré e pós-abate podem afetar essa qualidade (ALVES,2011). Dentre as várias características mencionadas para se obter um produto de alta qualidade, a Capacidade de Retenção de Água (CRA) é uma das mais utilizadas (ABDULLAH et al.,2014).

A CRA corresponde a capacidade da carne em reter água durante o seu processo de corte, moagem e prensagem. O músculo suíno é composto por uma parte significativa de água. Em alguns tipos de cortes a água representa até 75% do seu peso total (ABDULLAH et al.,2014). Os níveis de concentração de água na carne suína estão relacionados diretamente com o seu aspecto visual, maciez, suculência, firmeza e rendimento durante o preparo. Isto é, em uma carne pobre de CRA esses aspectos mencionados são afetados negativamente, resultando em uma carne com aspecto visual inferior e mais seca do que o convencional, e também de pouco rendimento durante o seu preparo (GUNENC,2007).

Atualmente, existem diversas técnicas e trabalhos capazes de mensurar a CRA de carnes suínas ((JOO,2018), (FILHO et al.,2017), (KATOH,1981)). Geralmente, as técnicas mais utilizadas são baseadas no método proposto por (GRAU; HAMM,1953),

que utiliza a compressão de amostras para mensurar a CRA da carne (JOO,2018). Esse tipo de técnica consiste em analisar a quantidade de água retida em pequenas amostras de cortes de músculos nas quais são colocadas sobre filtros de papéis previamente numerados, entre duas placas, normalmente de acrílico ou plástico. Em seguida, são adicionados pesos sobre o material por um determinado tempo. Ao pressionar a amostra com o peso, a água retida no músculo é expelida e absorvida pelo papel, com isso uma mancha correspondente a água da amostra é formada. Após o processo, a área da carne prensada é demarcada a caneta por um profissional especialista, formando duas áreas sobrepostas em relação ao suco liberado pelo método, conforme exemplificado na Figura1.

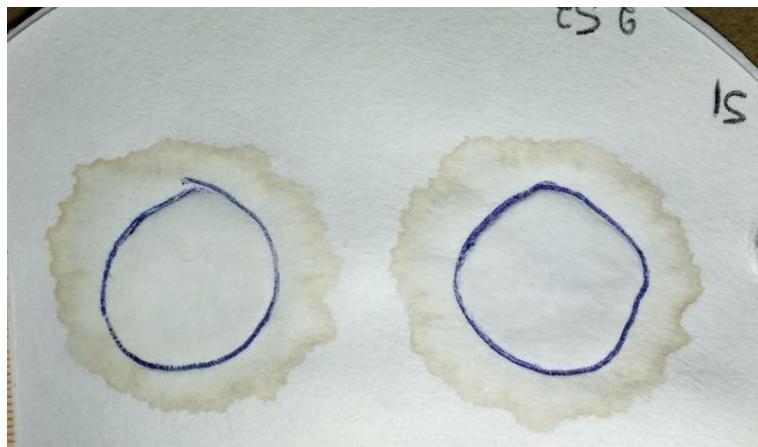


Figura 1 – Exemplo de amostras com suas áreas sobrepostas após a aplicação do método de compressão.

Após a aplicação do método, o profissional responsável analisa a quantidade de água retida em cada amostra, medindo e comparando as regiões internas e externas das amostras. A CRA de cada amostra é calculada através da relação entre o tamanho da porção de carne prensada (área interna) e a região total da amostra (área externa). Em alguns casos, como no trabalho de (ALVES,2011), os profissionais especialistas fotografam as amostras e utilizam softwares de processamento de imagens como o ImageJ® para identificar e quantificar as regiões formadas pelo método de compressão.

Apesar do auxílio desses softwares, todo o trabalho de identificação das regiões e o cálculo da CRA ainda são realizados de forma manual pelos especialistas. Por esse motivo, o tempo necessário para realização do trabalho tende a ser maior na medida em que a quantidade de amostras a serem analisadas aumenta. Desse modo, muitas das vezes também é necessário aumentar o número de profissionais envolvidos para execução dessas tarefas, o que pode tornar o trabalho ainda mais caro financeiramente. Outra preocupação é justamente com a precisão das análises, pois esse tipo de trabalho está sujeito a falhas e ao cansaço do profissional, o que pode influenciar diretamente no resultado final da técnica. Também é importante ressaltar que por se tratar de um trabalho manual, medições de uma mesma amostra realizadas por especialistas diferentes podem apresentar resultados variados.

Diante da importância do tema abordado e as dificuldades enfrentadas pelos especialistas durante o processo de análise de CRA das amostras, há a necessidade de que todo esse processo seja automatizado. Para isso, técnicas de Processamento Digital de Imagens (PDI) podem ser muito úteis no processo de identificação das regiões de interesse e no cálculo da CRA.

1.1 Motivação

Na Literatura existem vários trabalhos que tratam sobre o tema de quantificação de CRA ((ALVES,2011), (KAEWTHONG; WAIYAGAN; WATTANACHANT,2017), (ELMASRY; SUN; ALLEN,2011)). No entanto, não há muitos relatos de trabalhos que utilizam técnicas de PDI para segmentar automaticamente as regiões das amostras obtidas via método de compressão. Com base na escassez de pesquisas relacionadas ao tema e com o intuito de ajudar os profissionais no processo de análise das amostras, desenvolvemos um método de segmentação automática capaz de quantificar as CRAs de amostras de carnes suínas obtidas via método de compressão.

O desenvolvimento do método proposto permite que futuramente sejam criados sistemas capazes de auxiliarem os profissionais durante o processo de análise das amostras. Possibilitará, principalmente, a criação de sistemas móveis onde todo o processo, incluindo a aquisição das imagens, poderá ser realizado diretamente no local onde o profissional estiver. Sendo assim, todo o trabalho de análise e extração de CRA se tornará mais prático, rápido, preciso e barato.

1.2 Objetivos e Desafios da Pesquisa

O objetivo principal deste trabalho foi propor um método de segmentação e quantificação automática de CRA de amostras de carnes suínas obtidas via método de compressão, que seja capaz de identificar as regiões de interesse e calcular as CRAs de forma satisfatória.

1.2.1 Objetivos Específicos

- ❑ Estudo de diversas técnicas de PDI como correção de iluminação, realce, utilização de diferentes modelos de cores, limiarização e operações morfológicas.
- ❑ Selecionar as técnicas mais adequadas e propor um método automático de segmentação e cálculo de CRA de amostras capaz de identificar as regiões de interesse com altos índices de precisão.
- ❑ Aplicar o método proposto em imagens de amostras de carnes suínas obtidas via método de compressão.

- Analisar e avaliar os resultados provenientes da aplicação do método proposto durante este trabalho.

1.3 Organização da Dissertação

Este trabalho está organizado da seguinte maneira: no Capítulo 2 são apresentadas todas as fundamentações teóricas utilizadas durante a realização desta pesquisa. Nesse capítulo são demonstrados todos os detalhes referentes as técnicas de PDI utilizadas, assim como exemplos de trabalhos já desenvolvidos que compartilham ideias semelhantes a proposta deste trabalho. No Capítulo 3 encontra-se todos os detalhes do método proposto. Em seguida, no Capítulo 4, a eficiência do método proposto é avaliada a partir da realização de dois experimentos. Por fim, no Capítulo 5 são apresentadas as conclusões que os autores chegaram ao final deste trabalho, assim como sugestões de novos trabalhos a serem feitos para complementação da pesquisa.

CAPÍTULO 2

Fundamentação Teórica

Nesse capítulo serão apresentados todos os conceitos, técnicas e procedimentos utilizados pelo autor para o desenvolvimento deste trabalho. Dentre eles estão: realce de imagens, modelos de cores RGB e HSV, componentes conexos, operações morfológicas, algoritmo de agrupamento K-means, esqueletização, cálculo do menor caminho utilizando o algoritmo de Dijkstra, e segmentação.

2.1 Realce de imagens

O processo de realce de imagens consiste em manipular os valores dos pixels, com o objetivo de melhorar a visualização e facilitar a interpretação de informações para as mais diversas finalidades. Transformações de intensidades para correção de brilho e a manipulação de contraste são alguns dos exemplos de técnicas de realce (GONZALEZ; WOODS, 2008).

2.1.1 Correção de Brilho

Uma imagem digital monocromática pode ser matematicamente representada por uma função bidimensional $f(x,y)$, onde x e y correspondem à posição de cada pixel e f representa a sua intensidade naquele determinado ponto. O brilho é caracterizado como a média dos tons de intensidade de uma imagem. A quantidade de brilho influencia diretamente no aspecto visual de iluminação da imagem.

Muitas vezes as imagens analisadas podem estar claras demais ou muito escuras, o que pode prejudicar a sua interpretação, sendo necessária a aplicação de técnicas que melhorem o seu aspecto visual. Algumas delas utilizam operações ponto a ponto, como transformações logarítmicas, logarítmicas inversas e de potência.

No caso das correções de iluminação com transformações logarítmicas, o objetivo é aumentar o valor de intensidade de pontos baixos e diminuir valores altos. Na Equação 1

é possível observar essa transformação:

$$s = c * \log(1 + r) \quad (1)$$

onde c é uma constante, r representa a intensidade do pixel e s o resultado da operação.

Na Figura 2 é possível observar o comportamento de alguns tipos básicos de funções de transformação de intensidade, como as lineares (negativo e identidade), de potência (n -ésima potência e n -ésima raiz) e logarítmicas (log e log-inverso). Diferentemente das funções lineares, que formam retas em suas representações, as funções logarítmicas e de potência formam curvas na medida em que os valores das intensidades de entrada vão aumentando.

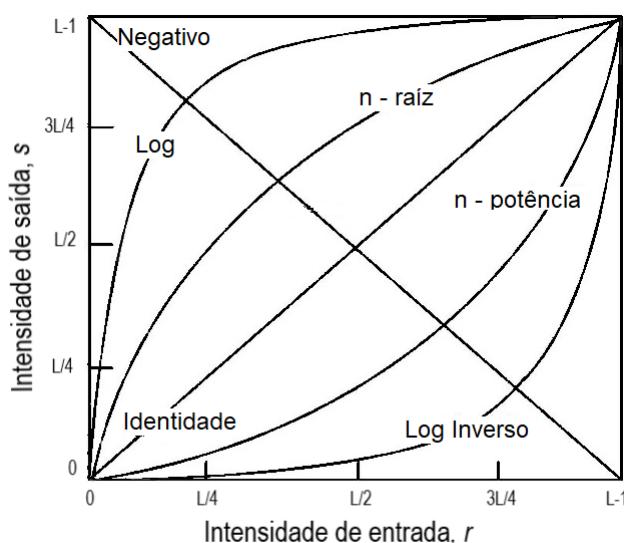


Figura 2 – Representação de funções básicas de transformações de intensidade, onde L corresponde ao número máximo de intensidade, r o valor de entrada e s o resultado.

Figura adaptada de: (GONZALEZ; WOODS,2008).

A função logarítmica tem uma importante característica que é a de comprimir faixas de imagens com grandes variações de intensidade de pixels. Para se chegar ao resultado desejado, a escolha do valor da constante c (mencionada na Equação 1) é extremamente importante, pois o peso atribuído a ela influencia diretamente no resultado final (GONZALEZ; WOODS,2008).

2.1.2 Contraste

O contraste pode ser definido como a diversidade de níveis de intensidade entre os pixels de uma imagem. Muitas vezes encontramos imagens com os níveis de contraste pouco distribuídos, o que pode prejudicar a sua visualização final. Essa diferença de valores dos pixels é fundamental para uma melhor identificação dos elementos de uma imagem (PRATT,2007).

Visualmente é possível observar as diferentes tonalidades de uma imagem a partir do seu histograma. O histograma nada mais é do que um gráfico, geralmente representado por barras, responsável por representar a distribuição da quantidade de pixels para cada valor de tom de cinza. Na Figura 3 é possível observar um exemplo de histograma.

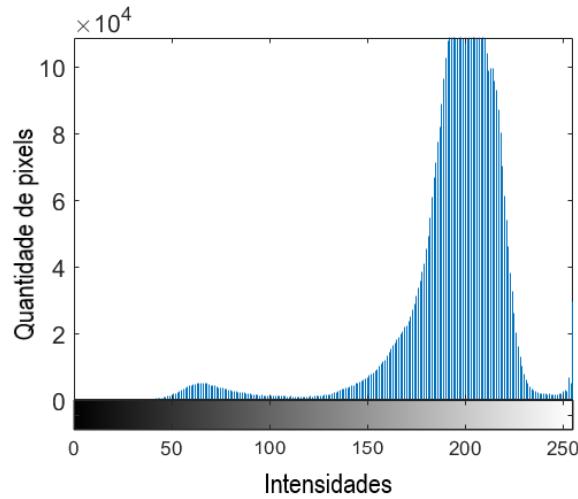


Figura 3 – Exemplo de um histograma, onde o sentido horizontal representa o valor da intensidade e o vertical à quantidade de pixels.

A partir da Equação 2 é possível calcular a distribuição de cada pixel do histograma:

$$p_r(r_k) = \frac{n_k}{n} \quad (2)$$

onde:

$0 \leq r_k \leq 1$, representando o k -ésimo valor de intensidade;

$k = 0, 1, \dots, L - 1$, no qual L corresponde ao número de tons de cinza;

n = número total de pixels da imagem;

$p_r(r_k)$ = probabilidade do k -ésimo nível;

n_k = número de pixels que o nível de intensidade corresponde a k .

Além de ser uma ferramenta estatística importante, existem diversas técnicas de manipulação do histograma que permitem fazer alterações no contraste de uma imagem. Alguns exemplos são as técnicas de equalização e expansão de histograma (FILHO; NETO, 1999).

A técnica de equalização de histograma consiste em redistribuir os valores de intensidade dos pixels de uma imagem, de forma que se obtenha um histograma uniforme, ou seja, no qual o percentual de pixels de qualquer tonalidade seja praticamente o mesmo,

resultando assim em uma imagem com maiores níveis de contraste (RUSS,2007). Segundo (FILHO; NETO,1999) é possível equalizar um histograma utilizando uma função de distribuição acumulada da distribuição de probabilidades original:

$$s_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k p_r(r_j) \quad (3)$$

sendo:

$0 \leq r_k \leq 1$, correspondendo ao k -ésimo valor de intensidade;

$k = 0, 1, \dots, L - 1$, no qual L corresponde ao número de tons de cinza;

s_k = resultado da equalização para o k -ésimo valor de intensidade.

Em casos onde são utilizados apenas uma pequena faixa de níveis de tons de cinza do histograma o método mais indicado é o método de expansão. Essa técnica consiste em aumentar a faixa de valores de intensidade disponíveis do histograma, ou seja, os tons de cinza de uma imagem são redistribuídos entre os novos limites inferiores e superiores (menor e maior valor do histograma). Isso torna pixels claros ainda mais claros e os escuros ainda mais escuros. Diferentemente da equalização, que redistribui os valores de forma uniforme com todas as posições, a expansão apenas aumenta a faixa de valores utilizados de forma proporcional ao seu histograma original (ANDREZZA,2015). A Equação de expansão de histograma é obtida por:

$$s = T(r) = \text{round}\left(\frac{r - r_{\min}}{r_{\max} - r_{\min}}(L - 1)\right) \quad (4)$$

onde:

r : níveis de intensidades atuais da imagem;

round : função de arredondamento para o inteiro mais próximo;

r_{\min} : corresponde ao menor nível de intensidade da imagem de entrada;

r_{\max} : o maior nível de intensidade da imagem de entrada;

L : corresponde ao nível máximo de intensidade possível;

round : função de arredondamento para o inteiro mais próximo;

s : intensidades da imagem após a transformação.

2.2 Modelo de Cores

Um modelo de cores, também conhecido como *espaço de cores*, tem como objetivo facilitar a especificação das mesmas de forma padronizada. Basicamente, um modelo de cores é uma especificação de um conjunto de coordenadas em um subespaço, onde cada cor é representada por um único ponto (GONZALEZ; WOODS,2008).

Existem inúmeros modelos de cores diferentes, como o RGB, HSV, YCbCr entre outros. A escolha do sistema está vinculada a quantidade de cor presente no objeto/ambiente capturado pelo dispositivo de aquisição. Sendo assim, existem espaços de cores que são maiores, ou seja, conseguem representar com mais fidelidade a imagem digitalizada (FEITOSA,2015).

Um dos sistemas de cores mais utilizados é o RGB. Por ser um modelo de cores orientado ao hardware, muitos monitores e câmeras de vídeo utilizam esse sistema (GONZALEZ; WOODS,2008). Tal modelo pode ser representado por um cubo, como mostrado na Figura4, onde os valores das cores primárias são representadas por vermelho (*Red - R*), verde (*Green - G*) e azul (*Blue - B*), dispostas em três vértices. Suas cores secundárias são o ciano, magenta e amarelo, também dispostas em outros três vértices. O preto pertence ao vértice de origem, enquanto o branco ao seu oposto. As cores no cubo podem variar da proporção de 0 a 1, sendo que esses valores representam o seu posicionamento dentro do cubo, relativo as retas (x,y,z).

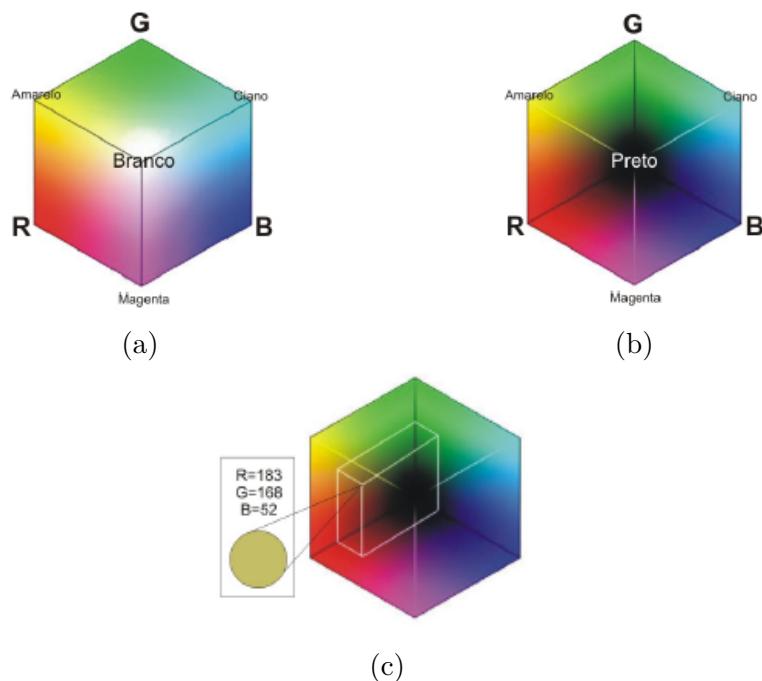


Figura 4 – Representação e localização de uma cor específica através do cubo RGB, sendo (a) a visão externa do cubo, (b) a visão interna e (c) a representação de uma cor específica.

Fonte (FEITOSA,2015)

No sistema RGB, os tons de cinza possuem os mesmos valores nos canais RGB, partindo da origem (*preto*) até o ponto mais distante (*branco*) (FEITOSA,2015).

O modelo HSV se diferencia de outros modelos como o RGB e CMYK pelo fato de ser um sistema altamente descritivo à percepção humana. Isso ocorre pois a interpretação do olho humano não se refere diretamente à combinação de cores primárias e sim pelos aspectos naturais como matiz, saturação e brilho. O HSV é formado justamente por esses atributos: Matiz (*Hue*), propriedade que descreve a cor pura; Saturação (*Saturation*), que descreve a medida que uma cor pura é diluída à luz e por último o Valor de intensidade (*Value*), responsável por representar o percentual de brilho da imagem. Este modelo consegue separar as informações de cores (matiz e saturação) do componente de intensidade, fazendo do modelo uma excelente ferramenta de auxílio na criação de algoritmos baseados em aspectos naturais e intuitivos à visão humana (GONZALEZ; WOODS,2008).

Ilustrativamente, o espaço de cores HSV pode ser representado por um cone, no qual suas propriedades são demonstradas na Figura 5e em sequência:

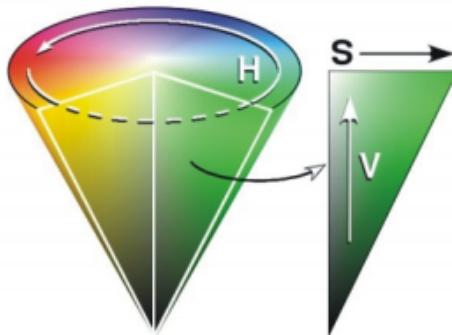


Figura 5 – Representação gráfica do funcionamento dos atributos do sistema HSV.

Fonte: (RIBEIRO,2007).

- **Hue:** o *matiz* corresponde às arestas do cone que variam de 0 a 360 graus. O seu valor varia conforme os ângulos do círculo, começando do vermelho (0°), passando por amarelo (60°), verde (120°), ciano (180°), azul (240°), magenta (300°) até novamente o vermelho (360°).
- **Saturation:** a *saturação* varia de 0 a 1, indicando a pureza de um determinado matiz. Quanto mais próximo o seu valor estiver ao contorno do cone (valor da saturação igual a 1), mais pura será o matiz, ou seja mais viva será a sensação da cor. Da mesma forma o contrário, quanto mais próximo do centro e de 0, mais impura será o matiz.
- **Value:** o *valor* da luminosidade também é calculado de 0 a 1, estando ele relacionado a quantidade de cor branca utilizada, ou seja, quanto mais próximo da base do cone maior serão as intensidades das cores da imagem. Isso também se aplica ao inverso, quanto mais próximo de 0, menor será o brilho (RIBEIRO,2007).

2.3 Operações morfológicas

O termo morfologia está ligado ao ramo da biologia que lida com a forma e estrutura dos animais. Matematicamente, na área de processamento de imagens, a ideia é semelhante, no sentido de analisar e extrair componentes que são úteis na descrição de formas de determinadas regiões, como fronteiras, esqueletos e fecho convexo. Trata-se de uma abordagem poderosa e unificada na resolução de vários problemas na área de processamento, desde operações de segmentações, filtragens, realces, entre outras (GONZALEZ; WOODS,2008).

A morfologia matemática tem como base a teoria dos conjuntos. Em uma imagem constituída por um conjunto de pixels, suas operações consistem em extrair informações e características relativas a geometria e topologia de um conjunto desconhecido a partir de outro conjunto conhecido, denominado *elemento estruturante*, sendo de grande importância a escolha correta do elemento estruturante para a obtenção de bons resultados (DUARTE,2015). Algumas operações morfológicas como a dilatação, erosão, abertura, fechamento, componentes conexos e preenchimento de regiões serão apresentadas a seguir.

2.3.1 Dilatação

A operação de dilatação é responsável por aumentar ou engrossar objetos de uma imagem. A forma específica e o tamanho dessa dilatação é controlada pelo formato do elemento estruturante.

Sendo A e B dois conjuntos de Z^2 (imagem binária), a dilatação de A por B é descrita como:

$$A \oplus B = \{c \in Z^2 | c = a + b, a \in A, b \in B\} \quad (5)$$

onde A corresponde a imagem a ser modificada e B ao elemento estruturante. A dilatação pode ser definida como o conjunto de todos os deslocamentos c em que B sobreponha-se em pelo menos há um elemento da imagem A (GONZALEZ; WOODS,2008), como exemplificado na Figura6.

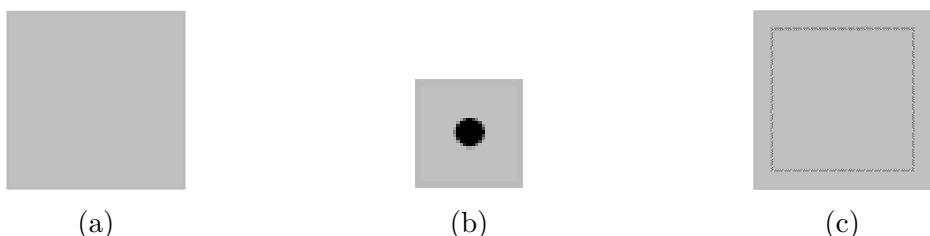


Figura 6 – Exemplo de dilatação, onde (a) representa o elemento A, (b) o elemento estruturante e (c) o resultado.

Essa técnica é muito utilizada na união de objetos e preenchimento de lacunas onde, por exemplo, é necessário ligar dois elementos próximos. A dilatação consegue expandir suas extremidades, conectando essas partes desconexas (GONZALEZ; WOODS,2008).

2.3.2 Erosão

Diferentemente da dilatação, a técnica de erosão é responsável por diminuir ou afinar objetos de uma imagem. Ela pode ser considerada como uma operação de *filtragem morfológica*, onde os detalhes menores que o elemento estruturante são filtrados ou removidos da imagem. Assim como na dilatação, a escolha do tamanho e forma do elemento estruturante é fundamental. Na Figura 7 é possível observar com maiores detalhes essa técnica.

Tendo A e B como conjuntos de uma imagem binária Z^2 , a erosão de A por B é dada por:

$$A \ominus B = \{c \in Z^2 | c + b \in A, \forall b \in B\} \quad (6)$$

onde, assim como na dilatação, A corresponde à imagem a ser modificada e B ao elemento estruturante. A erosão pode ser definida como o conjunto de todas as translações c , no qual B esteja totalmente alinhado a um elemento de A (GONZALEZ; WOODS,2008).

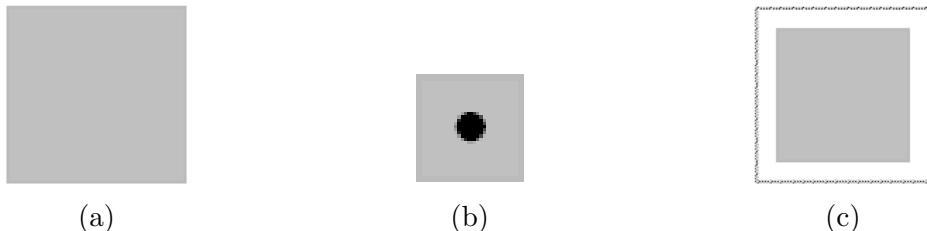


Figura 7 – Exemplo de erosão, sendo (a) o elemento A , (b) o elemento estruturante e (c) o resultado.

Fonte (FILHO; NETO,1999)

As operações de dilatação e erosão são consideradas duais em relação à complementação e reflexão de seus conjuntos. Desde que o elemento estruturante seja simétrico em relação à sua origem, é possível obter a dilatação erodindo o fundo da imagem e a erosão dilatando o fundo. Isso somente é possível porque a erosão de A por B equivale ao complemento da dilatação de A^c (complemento de A) por \hat{B} (reflexão de B) e vice-versa (GONZALEZ; WOODS,2008), como demonstrado na Equação 7:

$$(A \oplus B)^c = A^c \oplus \hat{B} \quad (7)$$

2.3.3 Abertura e Fechamento

Além das operações morfológicas discutidas até o momento, existem duas outras importantes que são a *abertura* e o *fechamento*. A abertura é responsável por suavizar os contornos de um objeto, remover pequenas ligações entre objetos e eliminar pequenas saliências finas, enquanto o fechamento também tende a suavizar contornos, porém normalmente funde estreitas descontinuidades, alonga áreas de golfos finos, além de retirar pequenos buracos e preencher lacunas. Dado um conjunto A e um elemento estruturante B , a abertura é definida da seguinte forma:

$$A \circ B = (A \ominus B) \oplus B \quad (8)$$

onde a abertura de A por B corresponde a erosão de A por B seguida por uma dilatação da resposta por B . A Figura 8 apresenta um exemplo de abertura.

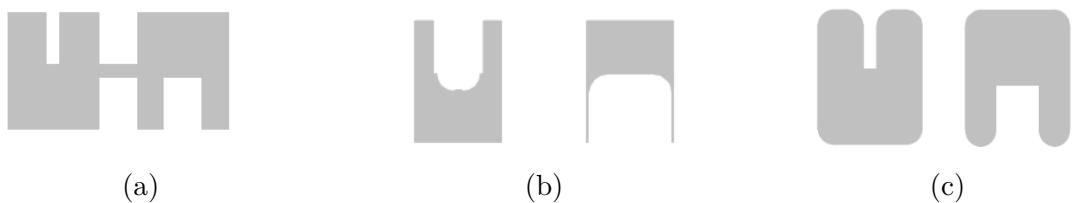


Figura 8 – Exemplo de abertura, onde (a) representa a imagem original, (b) a imagem após a erosão e (c) o resultado após a dilatação.

Fonte (FILHO; NETO, 1999)

O mesmo se aplica a operação de fechamento, demonstrado por $A \bullet B$ na Equação 9:

$$A \bullet B = (A \oplus B) \ominus B \quad (9)$$

onde o resultado é obtido pela dilatação de A por B , seguida pela erosão do resultado por B . A Figura 9 apresenta um exemplo de fechamento.

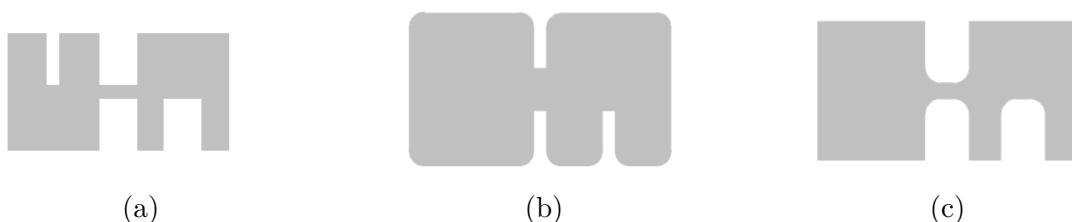


Figura 9 – Exemplo de fechamento, onde (a) representa a imagem original, (b) a imagem após a dilatação e (c) o resultado após a erosão.

Fonte (FILHO; NETO, 1999)

2.3.4 Componentes Conexos

A conectividade entre pixels é um importante conceito da área de processamento digital de imagens e é responsável por estabelecer limites entre objetos e definir regiões de uma imagem. Conforme já mencionado, uma imagem digital é formada por uma matriz de pixels. Normalmente, um pixel p na coordenada (x,y) tem quatro vizinhos horizontais e verticais, e as suas coordenadas correspondem a: $(x+1, y)$, $(x-1, y)$, $(x, y+1)$ e $(x, y-1)$. Esse conjunto de pixels são conhecidos como 4-vizinhança de p . Os vizinhos localizados nas diagonais de p , representados pelas coordenadas $(x-1, y-1)$, $(x-1, y+1)$, $(x+1, y-1)$ e $(x+1, y+1)$, formam o conjunto $N_d(p)$. A união dos conjuntos de vizinhos $N_4(p)$ e $N_d(p)$ gera a vizinhança $N_8(p)$, correspondente aos seus oito vizinhos (FILHO; NETO,1999), como representado na Figura10.

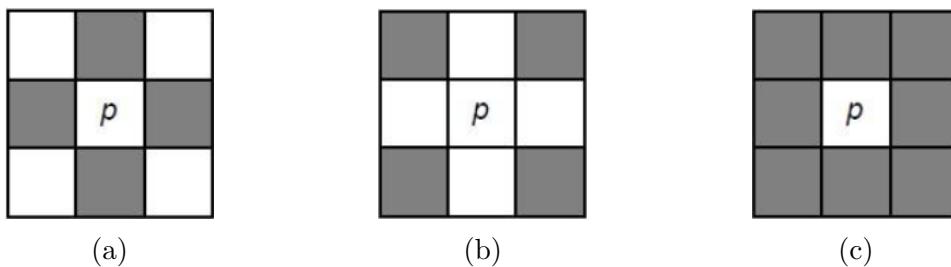


Figura 10 – Representação dos conceitos vizinhança, onde (a) corresponde a 4-vizinhança, (b) vizinhança diagonal e (c) 8-vizinhança.

Fonte (FILHO; NETO,1999)

Para determinar se os pixels estão conectados, primeiramente é necessário verificar se eles são adjacentes. Isto é, observar além do fator vizinhança se os níveis de intensidade obedecem a alguma regra de similaridade (FILHO; NETO,1999). Em uma imagem binária, representada pelo conjunto V , onde a adjacência é definida por $V = \{1\}$, ou seja, para serem adjacentes além de vizinhos os pixels devem possuir valor igual a 1. No caso de uma imagem com tons de cinza a ideia é semelhante, porém o tamanho do conjunto V será maior, pois serão criados subconjuntos com parte dos 256 valores disponíveis (GONZALEZ; WOODS,2008). Por exemplo, $V = \{20, 21, \dots, 30\}$, a conexão se cumprirá apenas para os pixels que se encontram na faixa de valores entre 20 a 30 tons de cinza. A especificação da adjacência escolhida é fundamental para a determinação da existência de objetos conexos, pois dependendo da posição do pixel certas áreas podem ser consideradas conectadas ou regiões disjuntas (GONZALEZ; WOODS,2008).

Um componente conexo pode ser definido como um subconjunto de pixels que são conexos entre si (JESUS,2011). Por exemplo, seja S um subconjunto de pixels de uma imagem, o conjunto de elementos conectados a um determinado pixel em S é considerado um componente conexo. Caso exista apenas S na imagem, então S é classificado como conjunto conexo. Na Figura11é possível observar exemplos de componentes conexos.

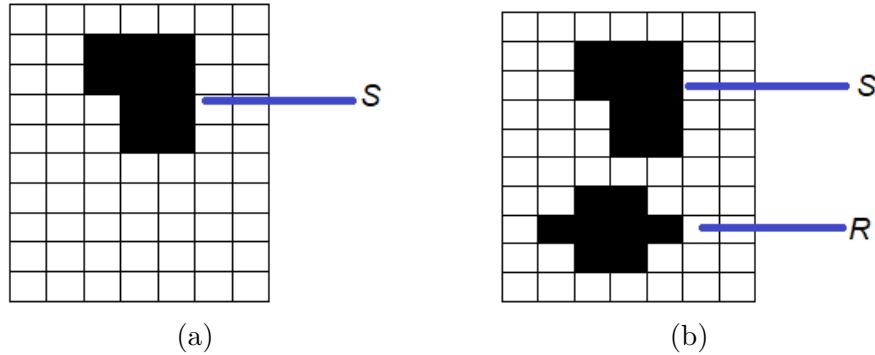


Figura 11 – Exemplos de conectividade em uma imagem binária, onde em (a) a coleção de pixels S representa um conjunto conexo e (b) os grupos de pixels S e R correspondem a componentes conexos.

A extração de componentes conexos é uma importante ferramenta de auxílio na identificação de objetos de uma imagem (GONZALEZ; WOODS,2008). Com o processo de rotulação de componentes conexos é possível identificar e separar os objetos de uma imagem em diferentes grupos. Algumas características como tamanho, formato, valor de intensidade e similaridade com outros objetos são importantes informações para determinar a distribuição de rótulos. O processo de rotulação consiste em atribuir diferentes etiquetas para cada componente conexo encontrado. Por exemplo, a atribuição de números de identificação para cada componente conexo. Após a rotulação de cada região é possível identificar com maior facilidade os objetos de uma imagem (SANTOS,2018), como demonstrado na Figura12.

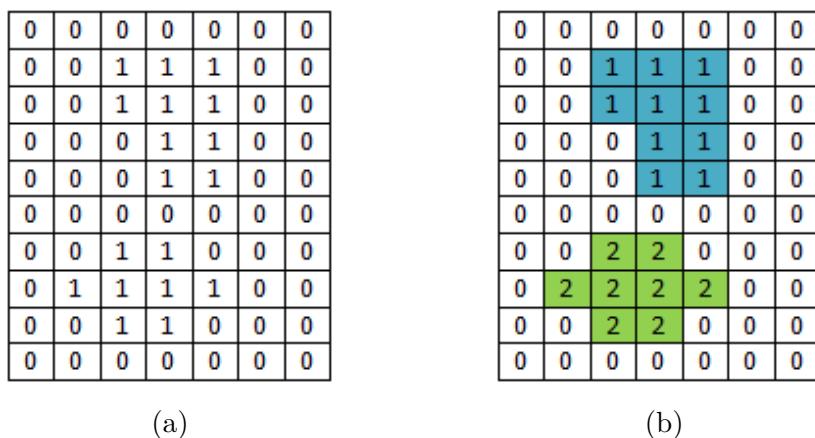


Figura 12 – Representação do processo de rotulação de componentes conexos, onde (a) representa uma imagem binária, na qual os pixels do fundo correspondem a 0 e os objetos equivalem a 1 e (b) a rotulação e destaque dos dois componentes conexos presentes na imagem.

2.3.5 Preenchimento de Regiões (buracos)

Em processamento digital de imagens, um *buraco* pode ser definido como uma região de fundo da imagem cercada por uma borda fechada de pixels conectados com valores

diferentes do fundo. Ou seja, dada uma imagem binária, as regiões de buracos terão valores iguais a 0 e os pixels da borda serão equivalentes a 1. O objetivo da técnica de preenchimento de regiões é preencher todas essas áreas internas de um objeto com pixels iguais a 1 por meio de operações de dilatação, complementação e intersecção.

O processo de preenchimento de regiões divide os componentes de interesse em dois grupos. O conjunto A representa os pixels do objeto e X os componentes de A mais a região interna a ser preenchida. O primeiro passo é atribuir algum ponto de X como 1 e a partir dele são realizadas sucessivas operações de dilatação em cada elemento de X , desde que satisfaça a relação de intersecção com o complemento de A . Dessa forma, a dilatação ocorrerá somente nas regiões de interesse. O procedimento representado pela Equação 10 irá se repetir até que a k -ésima iteração corresponda ao último elemento de X , isto é, até que todos os pixels da região interna também sejam iguais a 1:

$$X_k = (X_{k-1} \oplus B) \cap A^c \quad k = 1, 2, 3, \dots \quad (10)$$

sendo B o elemento estruturante, k a iteração atual, A^c o complemento de A e X_k o resultado após a dilatação para o atual k .

A união dos conjuntos X_k com A corresponde a todos os pixels das regiões de bordas e seus elementos internos (GONZALEZ; WOODS, 2008). Na Figura 13 é possível observar com maiores detalhes todas as etapas dessa técnica.

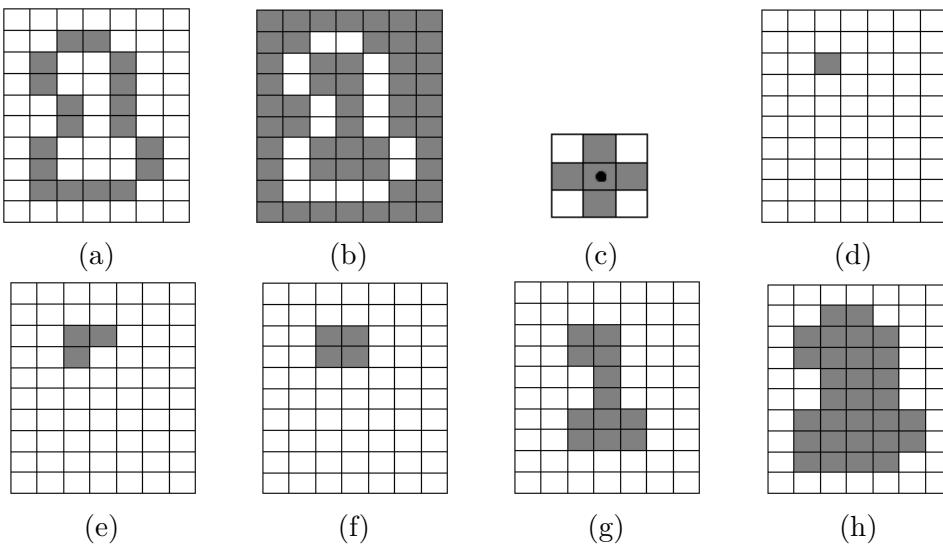


Figura 13 – Representação da técnica de preenchimento de regiões e suas iterações, onde (a) corresponde ao conjunto de pixels do objeto A , (b) o complemento de A , (c) o elemento estruturante, (d) marcação do pixel inicial X_0 , (e), (f) e (g) são representações de diferentes etapas após operações de dilatação (X_1 , X_2 e X_8 respectivamente) e (h) $X_8 \cup A$ representando a união do objeto original mais a sua área interna preenchida.

Figura adaptada de (GONZALEZ; WOODS, 2008)

2.3.6 Esqueletização

O esqueleto de uma região da imagem pode ser compreendido como uma versão simplificada da região original, onde todas as características essenciais do objeto são preservadas. Ao compactar essas regiões, o objetivo da técnica de esqueletização é justamente diminuir a quantidade de informações a ser processada para que, consequentemente, o tempo de processamento se torne menor. Normalmente a simplificação é alcançada através da utilização de técnicas de afinamento, responsáveis por afinar e reduzir as informações do objeto (PLOTZE,2004).

Segundo (SONKA; HLAVAC; BOYLE,2008), a ideia de esqueletização pode ser compreendida de forma análoga a um incêndio de um gramado. Supondo que o fogo comece nas regiões externas (bordas dos objetos) e se propague em direção ao centro com velocidade constante, as chamas serão apagadas no momento em que duas ou mais chamas se encontrarem. O esqueleto da imagem será formado por esses conjuntos de pontos de encontro. Essa definição é conhecida como Transformação do Eixo Medial (*Medial Axis Transformation - MAT*). Outra forma de se definir um esqueleto é por meio do conceito de *Disco Máximo*. Nessa metodologia, o esqueleto é caracterizado como linhas dos centros de discos que encostam nas bordas do objeto em dois ou mais pontos (ABREU,2016). Na Figura 14 é possível observar exemplos de esqueletização.

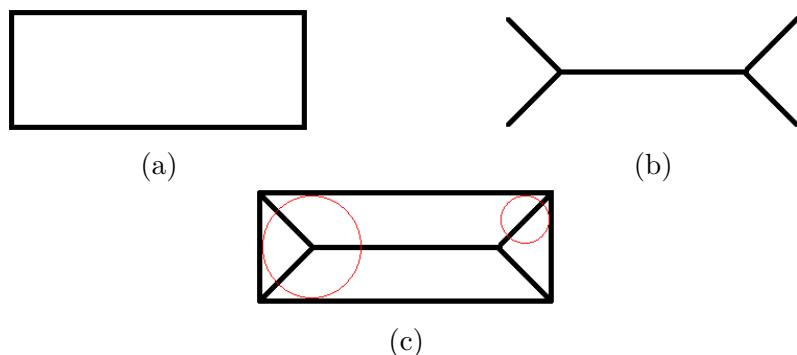


Figura 14 – Representação da técnica de esqueletização, onde (a) corresponde ao objeto original, (b) esqueleto por *MAT* e (c) esqueletização por *Disco Máximo*
Figura adaptada de (PLOTZE,2004) e (ABREU,2016)

Matematicamente, a técnica de esqueletização pode ser alcançada a partir do uso de operações constantes de erosão e abertura. Sendo A uma região formada por um conjunto de pixels, o seu esqueleto será obtido após sucessivas operações de erosões até que se encontre um limite correspondente ao passo anterior de A se tornar um conjunto vazio, como simplificado na Equação 11:

$$K = \max\{k | (A \ominus kB) \neq \emptyset\} \quad (11)$$

onde B representa o elemento estruturante, k a iteração atual e K a última erosão (GONZALEZ; WOODS,2008).

2.4 Algoritmo de Agrupamento K-means

O algoritmo *K-means* (também conhecido como *K-médias*) é um método de aprendizado não supervisionado responsável por agrupar elementos de um conjunto de dados. O objetivo dos algoritmos de agrupamento é separar o conjunto de dados em classes de acordo com algum critério de similaridade (WAGSTAF et al.,2001). Os objetos são separados em grupos, também chamados de *clusters*, de tal modo que os objetos presentes em um mesmo cluster sejam similares e objetos de grupos diferentes sejam distintos. Por ser um método não supervisionado o *K-means* não possui nenhuma informação sobre a rotulação dos objetos, ou seja, a classe a qual cada um dos objetos pertence é desconhecida pelo algoritmo. Dessa forma, os métodos não supervisionados utilizam apenas a similaridade das características dos dados para realizar o agrupamento de cada elemento (MALHEIROS,2017).

O principal propósito do *K-means* é partitionar os dados em k partições a partir do cálculo da média dos elementos centrais (centróides) de cada grupo. A distribuição dos elementos entre os k grupos geralmente é definida pela distância euclidiana entre os objetos e cada centróide, ou seja, um determinado elemento irá pertencer ao grupo cujo centróide for mais próximo dele. O algoritmo irá realizar várias iterações, onde a cada passo serão recalculados os centróides de cada grupo e os elementos redistribuídos entre as partições (SOUZA,2014). O procedimento irá se repetir até que uma função objetivo seja alcançada. De modo geral, repete-se o processo até que o erro quadrático seja minimizado, isto é, até que a distância entre grupos seja maximizada e a intra-grupo minimizada (GONDIM,2018). Na Figura 15 é possível observar um exemplo de execução do *K-means*.

Matematicamente, o método *K-means* busca dividir os dados em k partições, de modo que cada partição minimize a função objetivo de erro quadrático, como descrito na Equação 12. As k partições (ou *clusters*) podem ser representados por $C = \{C_1, C_2, \dots, C_k\}$ e a média das posições dos objetos centrais (ou centróides) de cada partição são representados por $m = \{m_1, m_2, \dots, m_k\}$ (DUDA; HART; STORK,2001).

$$Erro(C) = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2 \quad (12)$$

onde:

C é o conjunto das partições;

C_i corresponde a uma das partições;

p representa um ponto de C_i ;

m_i é o centróide de C_i .

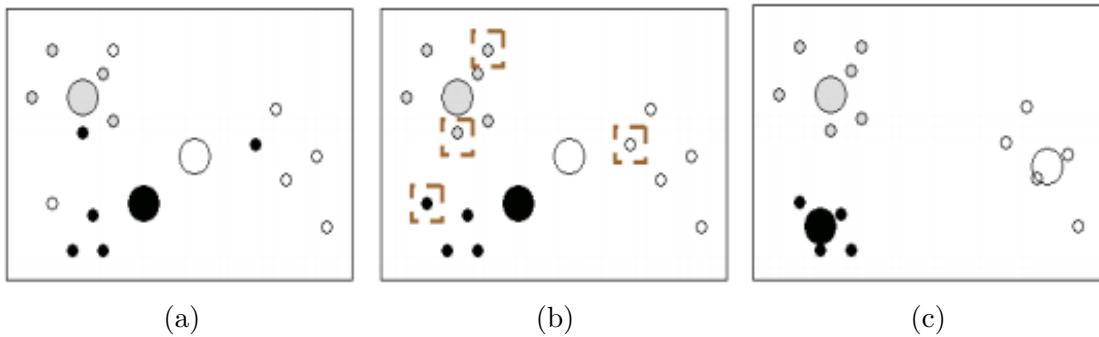


Figura 15 – Representação do particionamento de três classes pelo método *K-means*, onde em (a) é possível observar a geração dos centróides representados pelos círculos maiores e os pontos menores correspondem aos elementos do conjunto de dados, (b) cada ponto é atribuído ao grupo de centróide mais próximo e em (c) é alcançado o estado final com os centróides já recalculados.

Fonte (LINDEN,2009)

O funcionamento do algoritmo pode ser resumido em quatro etapas:

1. **Inicialização:** Com a base de dados a ser particionada já estabelecida, o número de centróides (k) é definido e em seguida são inicializados (geralmente selecionando amostras de forma aleatória).
2. **Agrupamento:** Para cada elemento do conjunto de dados é calculada a distância euclidiana para cada centróide. O elemento é atribuído ao grupo do centróide mais próximo.
3. **Atualização do Centróide:** O centróide de cada grupo formado no passo anterior é atualizado com a média dos elementos do cluster.
4. **Condição de Convergência:** Os passos 2 e 3 são repetidos até que alguma condição de convergência seja alcançada, no caso a minimização do erro quadrático (SOUZA,2014) e (LINDEN,2009).

2.5 Cálculo do Menor Caminho

De maneira simplificada, um grafo ou rede pode ser definido como um conjunto de objetos conectados entre si (MARIN,2013). Um grafo pode ser definido como $G(V,A)$, onde V representa um conjunto finito não vazio de objetos denominados vértices (ou nós) e A corresponde a um conjunto de pares ordenados, conhecidos como arestas, responsáveis por ligar um vértice a outro (NEGRI,2017). Tal aresta é composta por (u,v) , onde u corresponde ao vértice de início da aresta e v ao final (NEVES,2007).

Em teoria dos grafos, um caminho pode ser definido como uma sequência de vértices, de tal modo que cada vértice seguinte ao da sequência seja ligado por uma aresta (NEVES, 2007).

O problema dos caminhos mínimos é um dos desafios relacionados a grafos mais conhecidos e importantes da computação (UCHOA,2007). Tal problema consiste em encontrar o menor caminho (ou o caminho de menor custo) entre um determinado vértice inicial até um outro vértice de destino. O custo de um caminho está relacionado diretamente a quantidade de arestas (ou soma dos pesos numéricos atribuídos a cada aresta, caso seja um grafo ponderado). Portanto, quanto menor for a soma dos pesos ou menor a quantidade de arestas, menor será o trajeto até o vértice desejado (NEVES,2007). Na Figura16é possível observar a representação de um simples exemplo de grafo com arestas ponderadas positivas.

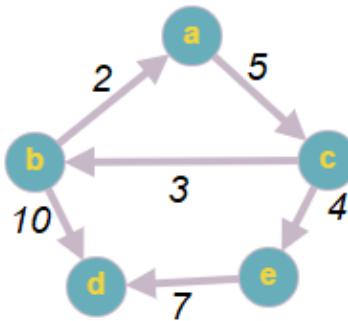


Figura 16 – Ilustração de um grafo com arestas ponderadas.

O algoritmo de Dijkstra é um dos métodos mais conhecidos e eficazes para solucionar o problema de encontrar o menor caminho de um grafo (desde que os pesos das arestas sejam não negativos). O algoritmo foi proposto em 1959 e é batizado com o nome do seu criador, o matemático holandês Edsger Dijkstra (NEGRI,2017). O objetivo do algoritmo de Dijkstra é encontrar um caminho em um grafo, cuja a soma das arestas entre um determinado vértice inicial e o de destino seja a menor possível (MARINS,2011).

Partindo de um determinado vértice inicial, o algoritmo irá calcular a menor distância possível entre o vértice atual e os seus vizinhos adjacentes ainda não visitados. Ao encontrar o vértice de menor custo dentre os disponíveis, o mesmo é escolhido e somente assim visitado. O processo irá se repetir até que todos os vértices do grafo sejam visitados. Caso o vértice atual não possua mais vértices adjacentes e ainda existam vértices não percorridos no grafo, o vértice não visitado mais próximo do vértice inicial é escolhido como atual e o processo é repetido até que todos os vértices sejam visitados e (consequentemente) encontrado o menor caminho entre o vértice inicial e o de destino (MARIN,2013).

O funcionamento do algoritmo de Dijkstra pode ser dividido em cinco passos:

Primeiro Passo: Inicialização dos vértices. A distância de um vértice inicial (s) para ele mesmo é 0 e o custo para os demais será temporariamente ∞ , pois o caminho

entre s e cada um dos vértices ainda é desconhecido.

Segundo Passo: Todos os vértices serão considerados como não visitados, exceto o vértice atual, no caso s .

Terceiro Passo: Calcular a distância entre o vértice atual e cada um dos seus vizinhos adjacentes não visitados. Sua distância será atualizada sempre que for encontrado um caminho menor do que o já conhecido para esse vértice.

Quarto Passo: Visitar o vértice que possuir a menor distância entre o vértice atual e os seus vizinhos adjacentes não visitados. Esse vértice recém visitado passará a ser o atual e a sua distância até o vértice inicial não será mais recalculada, pois ela já é a menor possível.

Quinto Passo: O algoritmo termina quando todos os vértices forem visitados. Caso ainda existam vértices não visitados, o que possuir a menor distância até o vértice inicial é escolhido como atual e o passo 3 volta a ser executado (DENGA et al., 2015).

Na Figura 17 é possível observar um exemplo de execução do algoritmo de Dijkstra em um grafo ponderado, onde os vértices em vermelho e as arestas em amarelo destacam o menor caminho entre o vértice inicial s e o de término t , totalizando um custo final igual a 10.

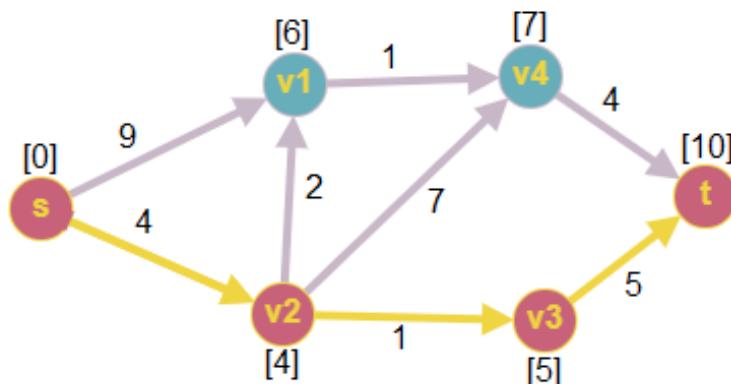


Figura 17 – Representação do menor caminho entre o vértice inicial s e o terminal t de um grafo ponderado, onde em cada aresta é possível observar o seu respectivo custo de deslocamento e cada vértice é rotulado com a menor distância entre s e ele mesmo.

2.6 Segmentação

A etapa de segmentação geralmente ocorre logo após o pré-processamento. O objetivo dessa técnica é subdividir uma imagem em regiões ou objetos. O ponto de parada da

segmentação é determinado quando as regiões ou objetos de interesse são detectados.

A segmentação é considerada uma das etapas mais difíceis do processamento de imagem, pois a precisão da detecção das áreas de interesse podem determinar o sucesso ou fracasso final dos procedimentos.

Apesar das inúmeras técnicas de segmentação existentes (GONZALEZ; WOODS, 2008), como a limiarização, detecção de bordas e clusterização, grande parte dos algoritmos se baseiam em duas propriedades básicas de valores de intensidade: descontinuidade e similaridade. A primeira busca dividir uma imagem a partir de mudanças bruscas de intensidade, como detecção de bordas. A segunda baseia-se na semelhança entre áreas que são pré-definidas a partir de determinados critérios. A limiarização e o crescimento de regiões são alguns exemplos dessa categoria (GONZALEZ; WOODS, 2008). Na sequência deste trabalho, a técnica de limiarização será apresentada de forma detalhada.

2.6.1 Limiarização

A técnica de limiarização consiste basicamente em segmentar uma imagem entre fundo e objeto (ou vários objetos) a partir de um limiar ou *threshold*, levando em consideração apenas os níveis de intensidade da imagem para diferenciar essas regiões.

Em casos mais simples, onde existem apenas duas classes, o histograma pode ser muito importante para se encontrar um limiar. Nesse caso, as classes de objetos são identificadas pela formação de picos de intensidades e o limiar se encontra no menor nível de intensidade entre essas regiões, em áreas denominadas vales. Geralmente, as intensidades maiores ou iguais a esse limiar são consideradas como objeto e as inferiores representam o fundo da imagem (FREITAS, 2012). Na Figura 18 é possível observar um exemplo de limiarização.

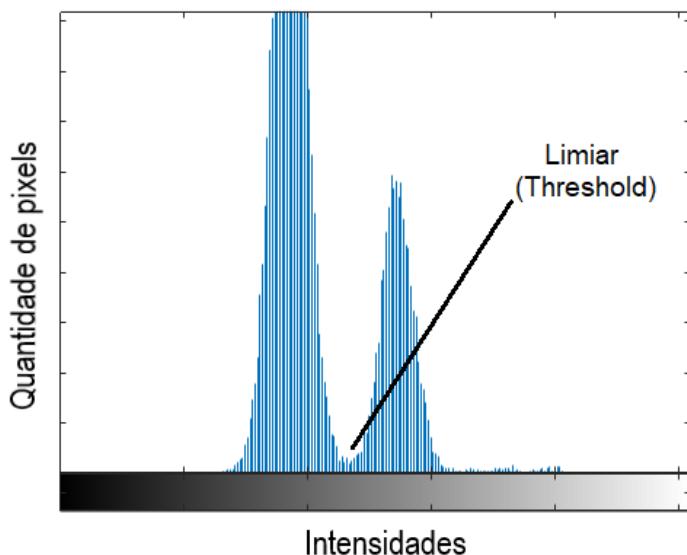


Figura 18 – Exemplo de limiarização entre duas classes de objetos em um histograma.

Portanto, a partir de um limiar T , qualquer ponto (x,y) de uma imagem $f(x,y) \geq T$

é determinado como objeto e $f(x,y) < T$, fundo, ou em determinados casos, o contrário (GONZALEZ; WOODS,2008), como descrito na Equação13:

$$g(x,y) = \begin{cases} 0, & \text{se } f(x,y) < T \\ 1, & \text{se } f(x,y) \geq T \end{cases} \quad (13)$$

Em casos onde é necessário realizar uma limiarização com mais de dois objetos, a operação passa a se chamar limiarização múltipla (GONZALEZ; WOODS,2008). Um exemplo de dois objetos e o fundo da imagem pode ser ilustrado na Equação14:

$$g(x,y) = \begin{cases} 0, & \text{se } f(x,y) \leq T_1 \\ 1, & \text{se } T_1 < f(x,y) \leq T_2 \\ 2, & \text{se } f(x,y) > T_2 \end{cases} \quad (14)$$

onde um ponto (x,y) pertence ao fundo se $f(x,y) \leq T_1$, ao primeiro objeto se $T_1 < f(x,y) \leq T_2$ e ao segundo objeto se $f(x,y) > T_2$ (GONZALEZ; WOODS,2008).

Portanto, a limiarização pode ser interpretada como uma operação que envolve uma avaliação em relação a função do tipo $T = [xyp(x,y) f(x,y)]$, onde $f(x,y)$ é o nível de intensidade (x,y) e $p(x,y)$ indica alguma propriedade local desse ponto, como a sua vizinhança. Quando T depende apenas de $f(x,y)$, a operação é denominada como limiar global. Nos casos onde T depende de $f(x,y)$ e $p(x,y)$, o limiar é considerado local. Podem também existir casos onde T depende das coordenadas espaciais de (x,y) . Nesse caso, o limiar é denominado como dinâmico ou adaptativo (FILHO; NETO,1999).

2.7 Trabalhos Relacionados

Nesta seção serão apresentados alguns trabalhos que compartilham ideias semelhantes a proposta deste trabalho. Todas as seguintes técnicas abordam o tema de qualidade de carne, principalmente sobre a técnica de CRA (Capacidade de Retenção de Água).

O trabalho de (ALVES,2011) tem como objetivo avaliar a qualidade da carne suína após o abate a partir da realização de dois estudos. No primeiro é analisado o efeito do gene Halotano sobre a deposição de gordura intramuscular e no segundo, o qual está relacionado diretamente ao tema deste trabalho, são constatadas as consequências da suplementação com determinados minerais no pré-abate. Algumas características como a CRA foram utilizadas para mensurar possíveis alterações.

Além de fatores como espécie animal, raça, sexo, peso e idade, a nutrição também é muito importante para melhorar a qualidade da carne, além de servir como tema de várias pesquisas. Com este intuito, foram realizadas experiências de suplementação dietética com minerais, a fim de prover melhorias na qualidade final da carne de suínos. Para mensurar a capacidade de água retida, foi utilizado o método de compressão. Nesse método, duas

amostras de cubo de carne de aproximadamente 0,5g são obtidas e pesadas com o auxílio de uma balança eletrônica de precisão. Em seguida elas são colocadas em papéis de filtro, previamente numerados, entre duas placas de acrílico. Posteriormente, é colocado um peso de 10kg sobre o material por um período de 5 minutos. Após esse prazo, a carne prensada é contornada por uma caneta esferográfica e o suco liberado formam duas áreas sobrepostas (ALVES,2011). Os detalhes e as etapas de aplicação dessa técnica são demonstrados na Figura19.

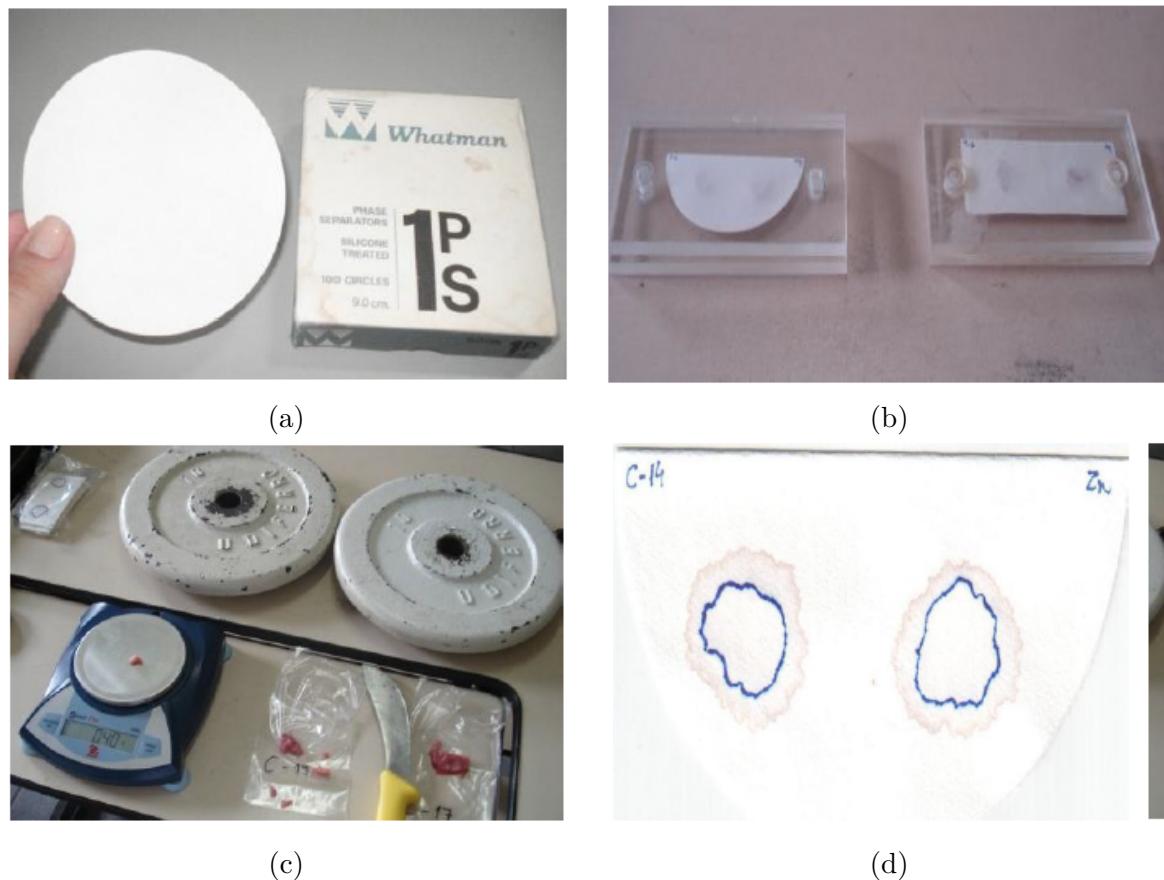


Figura 19 – Etapas do método de compressão. A letra (a) representa a primeira etapa, onde são colocadas as amostras de carne sobre os filtros de papel, em (b) são adicionadas as placas de acrílico entre as amostras, em (c) as anilhas são colocadas em cima do material e por último, (d) representa a análise e quantificação dos resultados.

Fonte (ALVES,2011)

Em seguida, as imagens foram analisadas e os resultados foram avaliados levando em consideração a área demarcada e a área total, variando entre 0 e 1 da menor para maior CRA, a partir da média entre as duas amostras.

Ao término do trabalho, a autora conclui afirmando que os animais submetidos a dieta hídrica à base de magnésio e selênio por um período de 12 horas apresentaram uma melhor qualidade de sua carne, em comparação aos que não tiveram esses minerais

como suplementação. Os outros animais suplementados com cobre e zinco não obtiveram grandes diferenças dos demais.

O trabalho de (KAEWTHONG; WAIYAGAN; WATTANACHANT, 2017) analisa a relação entre a coloração de amostras de peito de frango e algumas de suas características como composição química, pH e principalmente a capacidade de retenção de água.

Durante o trabalho os autores mencionam que geralmente os métodos convencionais de quantificação de CRA em carne de frango, como o gotejamento e cozimento, acabam destruindo as amostras de carne ao término do processo. Sabendo disso, os autores propõem um método não destrutivo capaz de capturar imagens de amostras de peito de frango via câmera digital, relacionando a coloração das amostras com algumas características como a capacidade de retenção de água. Na Figura 20 é possível observar o sistema de análise de imagens utilizado.

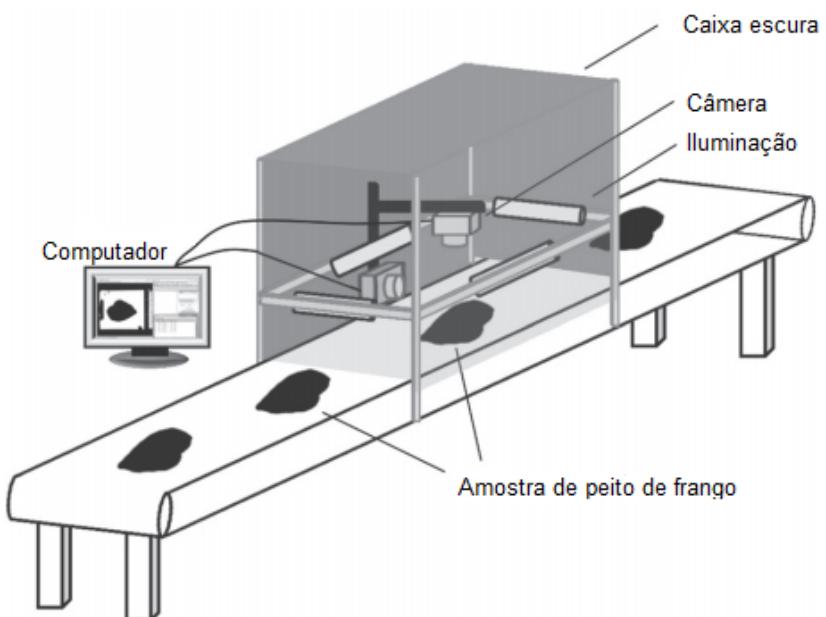


Figura 20 – Representação do sistema de análise de imagens de peito de frango via câmera digital.

Figura adaptada de (KAEWTHONG; WAIYAGAN; WATTANACHANT, 2017)

As análises de coloração das amostras de peito de frango foram realizadas utilizando o modelo de cores *CIE L*a*b**, onde L^* representa a luminosidade, a^* as cores verde e vermelho, e b^* o azul e o amarelo (KAEWTHONG; WAIYAGAN; WATTANACHANT, 2017). O L^* foi o valor escolhido para mensurar a qualidade das amostras. Carnes escuras são representadas por ($L^* < 50$), coloração normal ($50 \leq L^* \leq 56$) e amostras claras ($L^* > 56$). Dentre os resultados, observou-se que as amostras mais claras ($L^* > 56$) continham CRA menores do que as amostras com coloração normal ou escura.

Ao final do trabalho, os autores concluem que há uma grande correlação entre o valor L^* do modelo de cores utilizado e a capacidade de retenção de água das amostras.

Portanto, é possível constatar que a coloração do peito de frango pode ser muito útil para auxiliar na identificação de amostras com CRA baixo.

O trabalho de (ELMASRY; SUN; ALLEN,2011) tem como objetivo criar um método não destrutivo capaz de determinar a capacidade de retenção de água em amostras de carne bovina, utilizando imagens hiperespectrais na região do infravermelho próximo (*Hyperspectral Imaging Near Infrared - HI-NIR*).

Uma imagem hiperespectral é um conjunto de várias imagens de um mesmo objeto, onde cada imagem é representada por uma faixa de diferentes comprimentos de ondas eletromagnéticas (espectro) (ELMASRY; SUN; ALLEN,2011). Para a realização deste trabalho, apenas as faixas de ondas próximas ao infravermelho (entre 890nm e 1750nm) foram utilizadas.

Durante o estudo foram utilizadas amostras de 27 touros de diferentes regiões. Cada amostra foi escaneada individualmente por um sistema de aquisição de imagens hiperespectrais e em sequência essas imagens foram processadas com a finalidade de se descobrir a CRA de cada uma das amostras. Na Figura 21 é possível observar os detalhes dos componentes do sistema de análise de imagens utilizado.

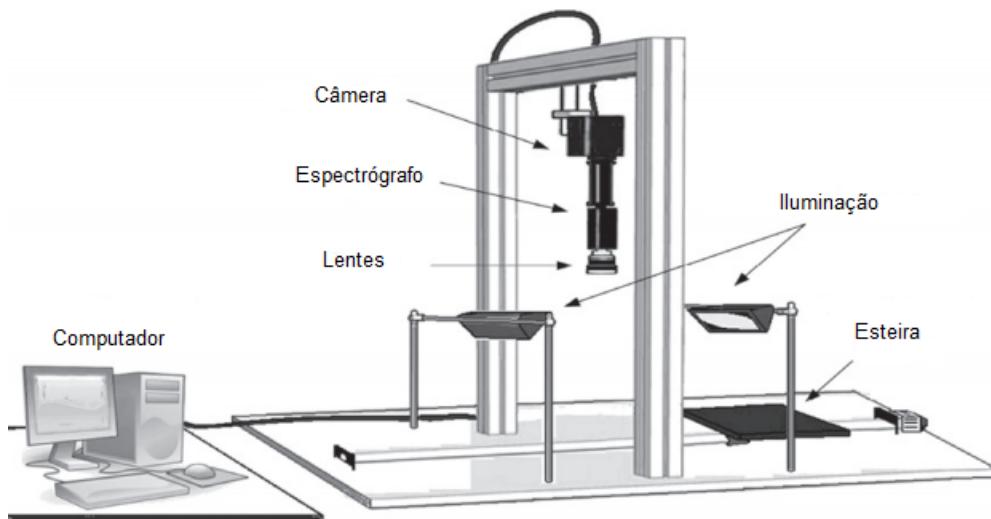


Figura 21 – Representação do sistema de análise de imagens hiperespectrais de carne bovina.

Figura adaptada de (ELMASRY; SUN; ALLEN,2011)

Após a aquisição das imagens é iniciado o processo de pré-processamento, responsável por realizar correções de iluminação nas imagens. Para se chegar ao efeito desejado, os autores utilizam duas imagens da amostra como referência, uma com o máximo possível de iluminação e a outra completamente escura. Essas duas referências são utilizadas para calcular a faixa espectral ideal de cada amostra, como demonstrado na Equação 15:

$$R = \frac{R_0 - B}{W - B} \times 100 \quad (15)$$

onde R é a faixa espectral corrigida, R_0 é a faixa espectral de entrada, B é a imagem referência escura e W a branca.

Já na etapa de segmentação, os autores utilizam uma série de operações de subtração entre os diferentes espectros das imagens e caso o resultado seja maior do que um determinado limiar, o ponto correspondente é segmentado. Ao final do processo é gerada uma máscara da amostra sem o fundo e os pontos de gordura, contendo apenas as regiões de interesse. Essa imagem resultante é denominada de *máscara magra*. Em seguida, os dados referentes as variações espetrais da máscara magra são armazenados para que em seguida essas informações sejam correlacionados com as quantificações reais de CRA via técnica de gotejamento. Os métodos de análise de componentes principais (*Principal Components Analysis - PCA*) e regressão por mínimos quadrados (*Partial Least Squares Regression - PLSR*) são os responsáveis pela tentativa de predição dos valores de CRA em cada amostra.

Segundo os autores, o método proposto obteve uma considerável taxa de acerto em suas predições (acima de 80%). Na Figura 22 é possível observar resultados da aplicação do sistema proposto em amostras de músculos bovinos.

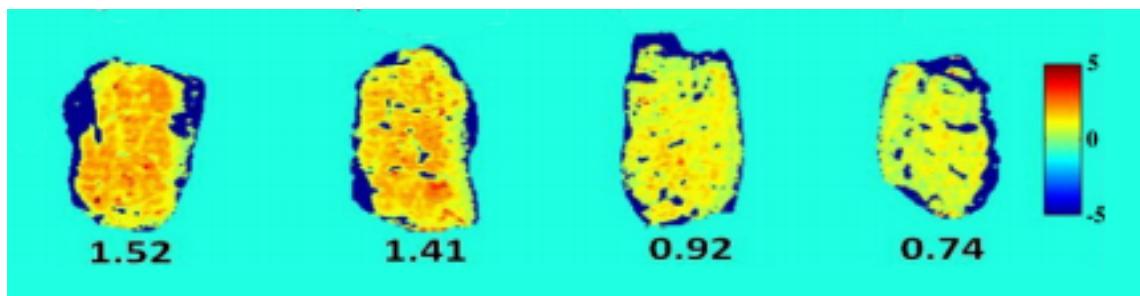


Figura 22 – Representação do mapa de distribuição de CRA em amostras de carnes bovinas via imagens hiperespectrais. Abaixo de cada uma delas é possível observar a média dos seus respectivos níveis de CRA, onde tons avermelhados correspondem a maiores quantidades de água retida.

Figura adaptada de (ELMASRY; SUN; ALLEN, 2011)

Ao final do trabalho, os autores concluem que o uso de imagens hiperespectrais podem ser uma potencial alternativa de método não invasivo de predição de níveis de CRA em carnes bovinas. Além de ser um processo rápido e não invasivo, o método proposto também demonstrou ser bastante eficiente.

2.7.1 Conclusão

Atualmente existem vários trabalhos na Literatura que propõem quantificar a CRA de diferentes tipos de proteína animal. No entanto, há poucos relatos de trabalhos que utilizam técnicas de PDI para automatizar o processo de análise e quantificação de CRA em carnes suínas, especialmente a partir do método de compressão de (GRAU; HAMM, 1953). Hoje em dia, profissionais da área até utilizam softwares de PDI, mas apenas

para analisar os tamanhos das regiões das amostras que terão as suas CRAs quantificadas (ALVES,2011). Todo esse trabalho é realizado de maneira inteiramente manual. Dessa forma, a quantificação de CRA de amostras de carnes suínas pelo método de compressão ainda é uma operação demorada, imprecisa, variável, relativamente cara e vulnerável a falhas e ao cansaço humano.

CAPÍTULO 3

Metodologia

3.1 Descrição Geral

A proposta deste trabalho é desenvolver um sistema computacional que utilize técnicas de segmentação em imagens de amostras de carne suína a fim de analisar e quantificar as regiões formadas pela técnica de CRA pelo método de compressão. A proposta deste trabalho é dividida em cinco grandes etapas: (a) preparação das imagens, (b) correção da iluminação, (c) segmentação da área externa, (d) segmentação da área interna e (e) cálculo da CRA. Durante os estudos, todos os algoritmos foram desenvolvidos utilizando o software MATLAB R2018b e executados em um computador com intel core i7-7700 (3.60 GHz) e 32GB de RAM.

A primeira etapa do trabalho é a preparação das imagens. Essa etapa é responsável por preparar as imagens para os passos subsequentes. Essa preparação consiste na aplicação de técnicas como a padronização da orientação de cada imagem, remoção de fundo e conversão do formato dos arquivos das imagens.

O próximo passo é a correção da iluminação. Devido as mais diferentes condições de iluminação do ambiente durante a aquisição das imagens e o modo de como elas foram adquiridas, muitas delas não possuíam uma distribuição ideal dos níveis de brilho. Dessa forma, a visualização das regiões de interesse poderiam ser prejudicadas. O objetivo dessa etapa é corrigir a iluminação das imagens para que as informações de interesse de cada uma delas sejam melhor visualizadas, facilitando assim o trabalho das próximas etapas.

O processo de segmentação foi dividido em duas etapas: segmentação das áreas externas e internas. A primeira é responsável por identificar e destacar os pixels pertencentes a área total (ou externa) de cada uma das manchas formadas pela aplicação da técnica de CRA. Essas áreas correspondem ao acúmulo de água de cada amostra de carne suína após serem compressadas. Já na segmentação interna o objetivo é segmentar as áreas internas demarcadas a caneta pelo profissional especialista. Essas regiões correspondem ao tamanho das amostras dos músculos suíños utilizadas para o cálculo de CRA.

Finalmente, o cálculo das áreas segmentadas e da CRA são as últimas etapas deste

trabalho. Nessa fase são calculadas as áreas das duas regiões segmentadas e a proporção entre as regiões internas e externas das amostras. Em sequência, as áreas segmentadas e as CRAs extraídas das amostras pelo método proposto são comparadas com as obtidas por um profissional. A finalidade dessa comparação é avaliar a precisão do método desenvolvido em relação a uma segmentação manual. Na Figura 23 é possível observar com maiores detalhes a ordem de execução das etapas que compõem o método proposto.

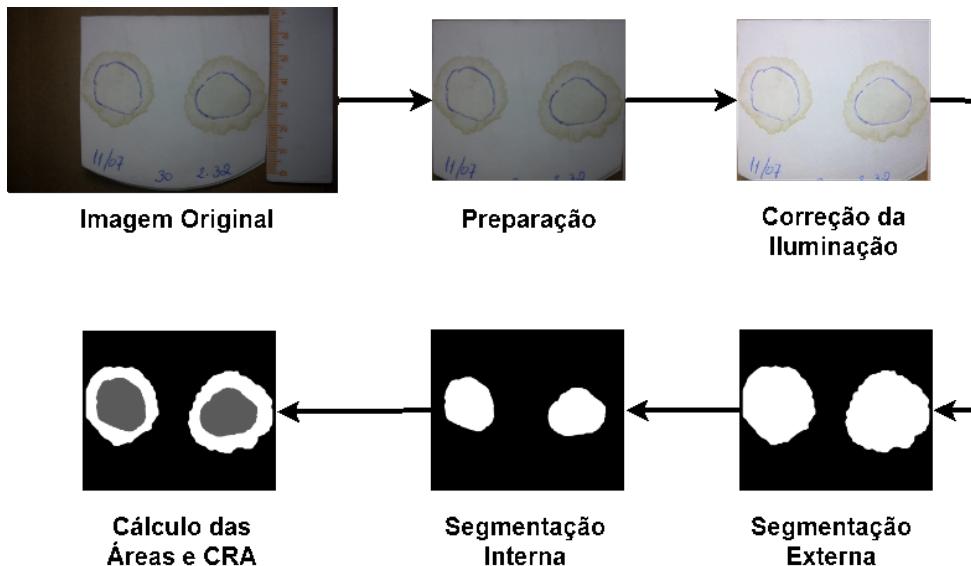


Figura 23 – Etapas do método proposto de avaliação da capacidade de retenção de água em amostras de carne suína.

3.2 Preparação das Imagens

Após a obtenção das imagens, o primeiro passo é realizar o processo de preparação das imagens, responsável por realizar ajustes e facilitar o trabalho das etapas seguintes. Durante essa fase foram executadas três tarefas diferentes: (a) conversão do formato dos arquivos, (b) reposicionamento da imagem e (c) recorte do fundo.

A primeira ação necessária foi converter todas as imagens salvas no formato *JPG* para o *PNG*. Alguns formatos de arquivos de imagens utilizam técnicas de compressão para reduzir a quantidade de dados necessários para se reproduzir uma imagem. No caso do *JPG* o tipo de compressão utilizada é a compressão com perdas (*lossy compression*), responsável por eliminar informações visualmente irrelevantes. Desta forma, ao salvar um arquivo em *JPG* algumas informações sobre a imagem original acabam sendo perdidas. Diferentemente do *JPG*, o formato *PNG* realiza um processo de compressão sem perdas (*lossless compression*), capaz de eliminar apenas informações redundantes, mantendo assim todas as detalhes da imagem original (GRAZIOSI, 2011; ZAGHETTO, 2009). Portanto, o objetivo é utilizar o formato *PNG* para que possíveis novas perdas de informações sejam evitadas nos passos seguintes.

Durante a etapa de aquisição, as imagens são fotografadas manualmente pelos profissionais responsáveis, geralmente em alta resolução (aproximadamente 4000 colunas e 2300 linhas cada). Muitas delas são fotografadas em diferentes ângulos por esses profissionais. Sabendo disso, todas as imagens foram padronizadas para que sejam visualizadas na posição horizontal, ou seja, o número de colunas da imagem deverá ser maior do que a quantidade de linhas. Sendo assim, todas as imagens que possuíam o número de linhas maior do que a quantidade de colunas foram rotacionadas em 90°. Dessa forma, todas as imagens passaram a seguir o mesmo padrão de posicionamento, como mostrado na Figura 24. Essa padronização permite facilitar a identificação das regiões de interesse durante as etapas seguintes.

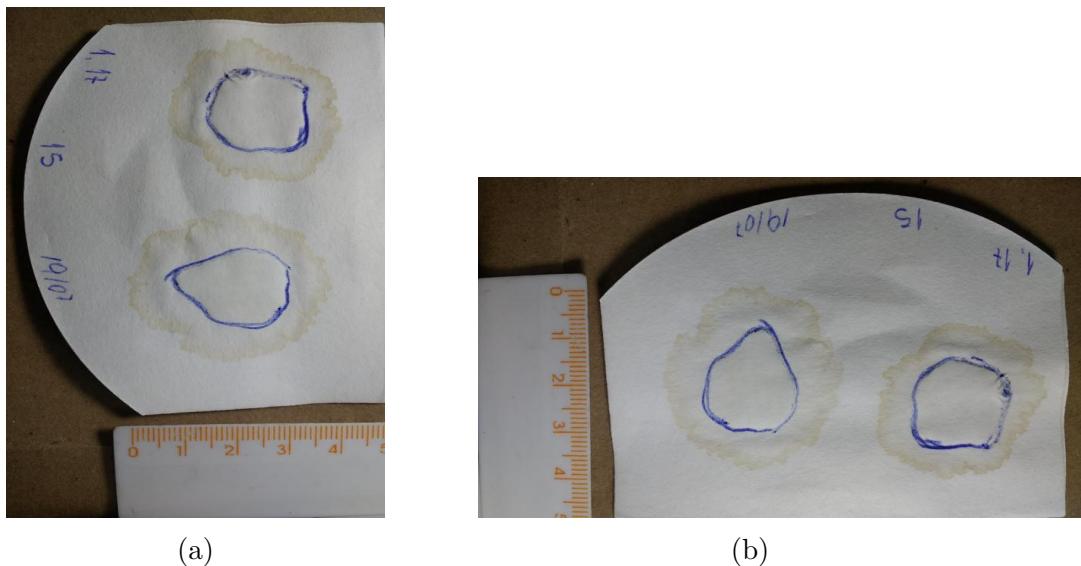


Figura 24 – Representação das primeiras etapas de preparação das imagens, onde (a) representa a imagem original e (b) a mesma rotacionada em 90° e convertida para *PNG*.

O próximo passo foi recortar as informações referentes ao fundo da imagem na tentativa de preservar somente as regiões pertencentes ao filtro de papel no qual são depositadas as amostras. O objetivo é manter somente as regiões de interesse para que as áreas de fundo não atrapalhem o trabalho das etapas de segmentação. Para a realização dessa tarefa, primeiramente é criada uma máscara referente a área de interesse (filtro de papel). Em sequência, a área dessa máscara é utilizada como base para a geração de uma nova imagem sem o fundo. Todos os detalhes das etapas de criação da máscara de recorte são detalhados a seguir:

Primeira Etapa: Eliminação de ruídos aplicando um filtro de suavização em formato de disco de raio igual a 10 pixels.

Segunda Etapa: Conversão do modelo de cores *RGB* para *HSV*. Com o modelo *HSV* é possível isolar a saturação da imagem e aplicar a limiarização. Pontos cuja saturação

são menores do que 20 são classificados como objeto.

Terceira Etapa: Isolamento da área correspondente ao papel. Utilização da operação morfológica de erosão com elemento estruturante no formato de disco de raio igual a 5 pixels. O objetivo dessa etapa é tentar separar a área correspondente ao papel dos outros objetos da imagem.

Quarta Etapa: O formato final da máscara é alcançado com a aplicação da técnica de preenchimento de regiões, onde áreas de pixels iguais a 0 com formato de *buracos* são preenchidas com pixels iguais a 1. Com a aplicação dessa técnica, todos os elementos não segmentados da área correspondente ao filtro de papel são preenchidos, formando um só objeto.

Na Figura 25 é possível observar um exemplo de extração da máscara para recorte de fundo.

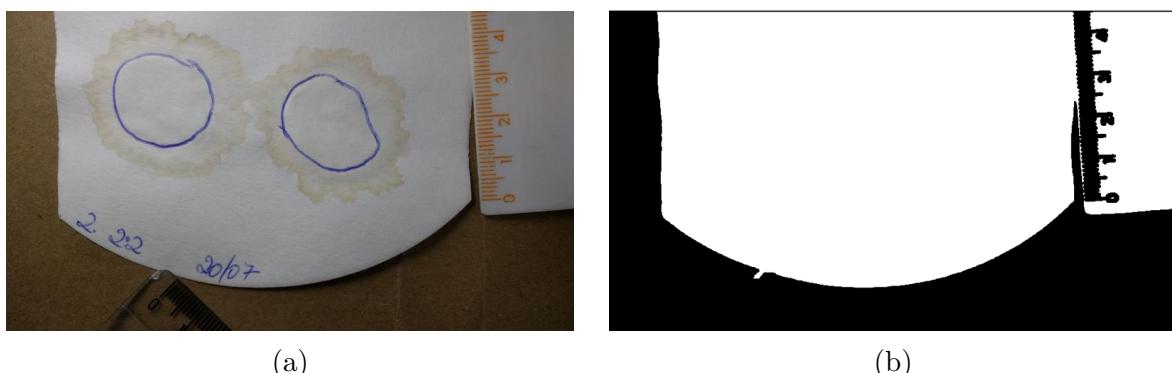


Figura 25 – Exemplo de extração da máscara de recorte de fundo, onde (a) representa a imagem original e (b) a máscara utilizada como referência para extração do fundo.

Após a criação da máscara, o passo seguinte é realizar o recorte da região de interesse da imagem original. Para a realização do recorte são verificadas as médias de intensidades de cada linha e coluna da máscara extraída no passo anterior. O objetivo é encontrar a região correspondente ao filtro de papel para que seja possível criar uma nova imagem contendo somente essa região e consequentemente todo o fundo da imagem original seja eliminado.

Inicialmente verificamos as médias de cada coluna da imagem com a finalidade de se encontrar possíveis regiões correspondentes ao filtro de papel. Os objetos da imagem são encontrados a partir da análise dos seus pontos iniciais e finais ao longo do processo de verificação das colunas. Considerando que o pixel branco equivale ao valor 1, um ponto inicial é identificado quando a média de uma das colunas é maior do que 0.45 e o ponto final será quando a média da próxima coluna for menor do que 0.45 . Essa faixa de colunas entre o ponto inicial e o final corresponde aos limites horizontais de um objeto da imagem

original. Também há a possibilidade de se encontrar mais de um objeto. Nessa situação, o de maior tamanho é escolhido como pertencente a região de interesse.

No caso das linhas, o processo é semelhante à verificação das colunas. A diferença é que o limiar passa a ser 0.6 . Ao término de todo processo, uma nova imagem é criada contendo apenas a região de interesse. Na Figura 26 é apresentado uma ilustração do processo de recorte. Na imagem utilizada como exemplo o recorte foi realizado nas primeiras 1644 linhas de um total de 2340 e passou a ter apenas 3007 colunas das 4160 anteriores.

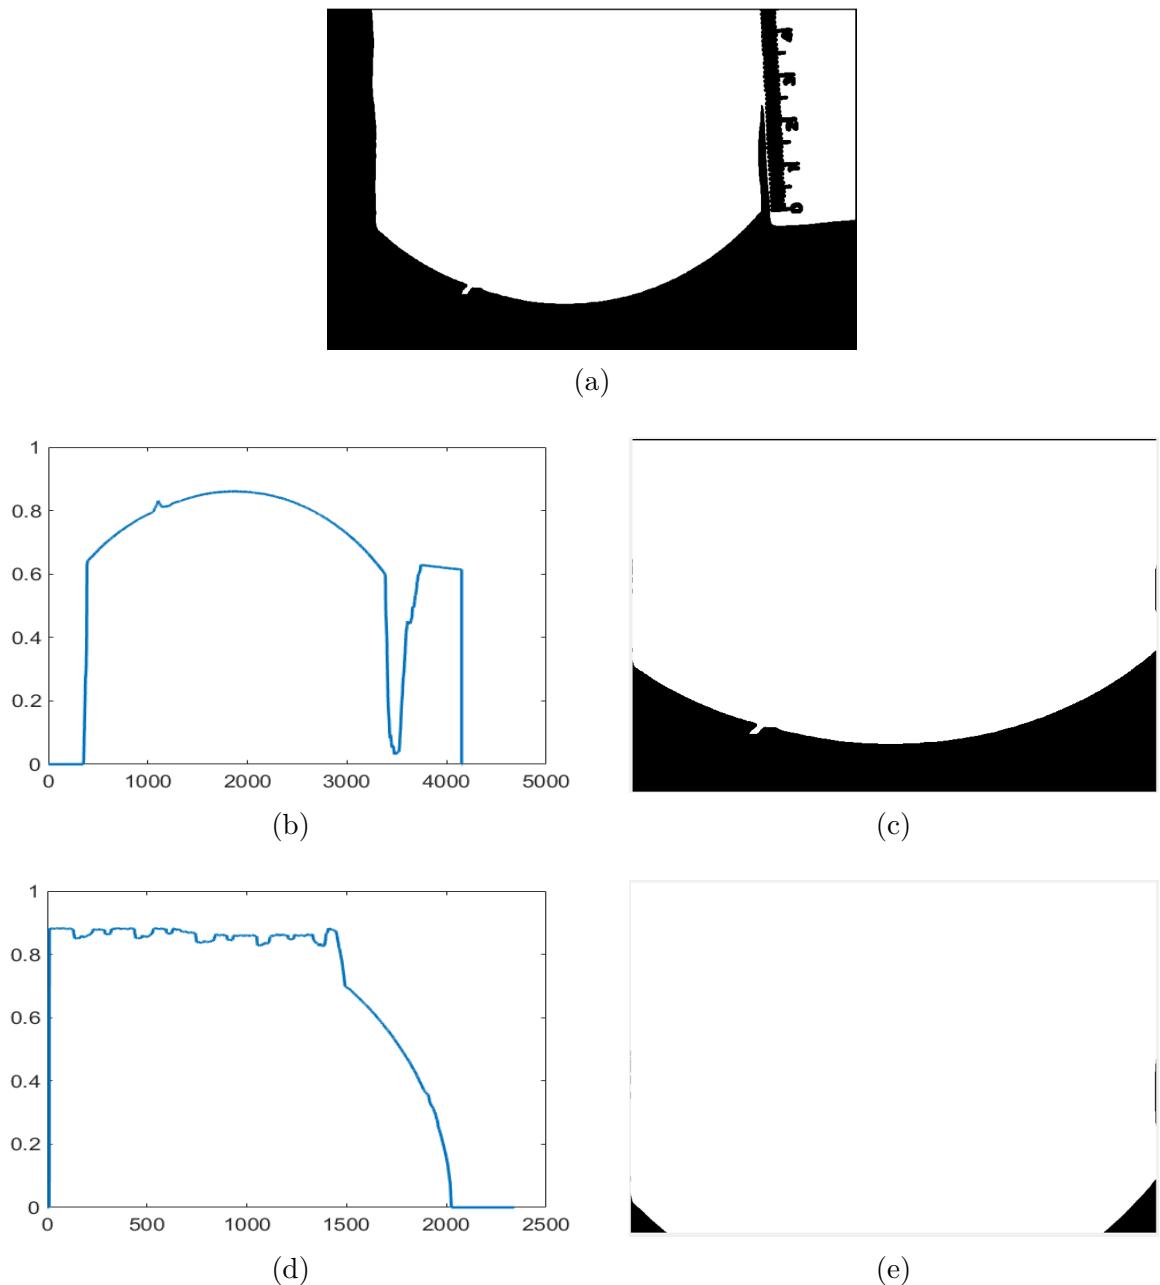


Figura 26 – Representação do processo de recorte, onde (a) corresponde à máscara original, (b) gráfico das médias de intensidade das colunas, (c) a máscara após o recorte das colunas, (d) gráfico das médias de intensidade das linhas e (e) o resultado da máscara após o recorte das linhas e colunas.

Na Figura 27 é possível observar a comparação entre uma imagem original com a região de interesse (cor vermelha Figura 27(a)) e a mesma após a aplicação da operação de recorte. É possível constatar que praticamente todo o fundo da imagem é recortado e que apenas as regiões de interesse são mantidas.

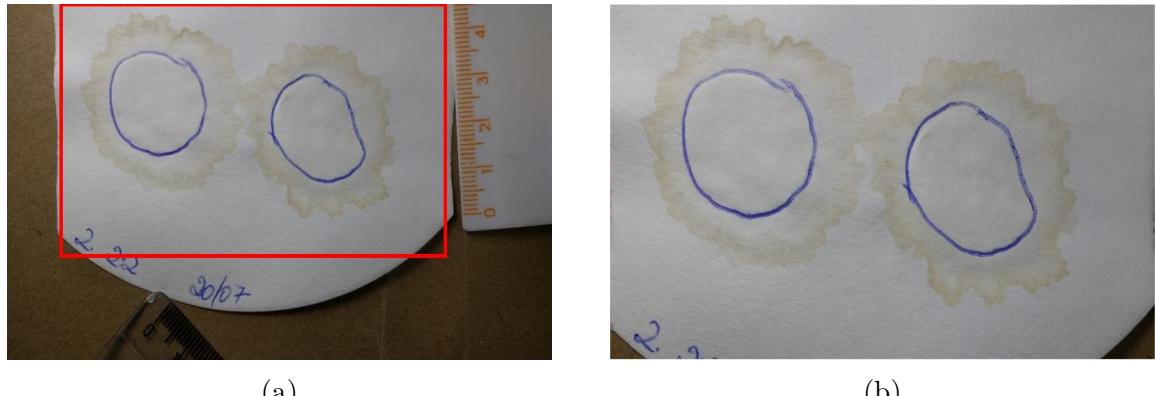


Figura 27 – Representação do resultado da aplicação da técnica de recorte de fundo, onde (a) representa a imagem original com a região de interesse destacada e (b) o resultado final da técnica de recorte de fundo.

3.3 Correção da Iluminação

A etapa de correção da iluminação é uma ação importante e necessária para melhorar a identificação das regiões de interesse da imagem. Essa correção é necessária devido as imagens das amostras terem sido capturadas em ambientes com diferentes condições de iluminação (ausência ou excesso de luz natural ou artificial). Devido a essas condições, o resultado foi a geração de imagens com cores e brilho irregulares, prejudicando assim a identificação das regiões de interesse. Além de cores desbalanceadas, as imagens apresentavam grande variação no brilho, oscilando entre regiões com valores muito altos (regiões claras) a muito baixos (regiões escuras). Durante essa fase foram executadas duas tarefas com finalidades diferentes: (a) correção do brilho e (b) correção dos canais *RGB*.

Buscando encontrar uma distribuição ideal das intensidades de brilho e com a imagem já convertida para o modelo *HSV*, algumas técnicas foram utilizadas para realizar alterações no brilho da imagem. A primeira delas foi o uso de uma operação logarítmica, onde a ideia é aumentar os pontos com intensidades baixas e diminuir os índices muito altos. Esse tipo de correção é realizada nos três canais *RGB* da imagem com os canais variando entre 0 e 1, e são utilizados diferentes fatores de multiplicação para cada região da imagem. Na Equação 16 é possível observar a Equação da transformação logarítmica utilizada:

$$s = c * \log(1 + r) \quad (16)$$

sendo que $r \in [0, 1]$ representa o valor do brilho de entrada, c é o fator de multiplicação e s é o resultado da transformação.

Regiões com tons mais escuros (intensidade baixa) necessitam de um aumento de intensidade maior. Assim, quanto mais escuro, maior deverá ser o fator de multiplicação utilizado. Já no caso das regiões claras (intensidade alta), a mudança precisa ser menor. Sendo assim, quanto mais clara for a região, menor será o fator de multiplicação. O critério para a escolha do cálculo do fator de multiplicação foi a média do brilho da vizinhança (uma janela de 10 pixels de lado), como demonstrado na Equação 17:

$$c = \begin{cases} 2.1 - (m^2)/0.9, & \text{se } m \leq 0.6 \\ 2.3 - v, & \text{se } 0.6 < m < 0.85 \\ 1.45, & \text{se } m \geq 0.85 \end{cases} \quad (17)$$

onde c representa o fator de multiplicação, m a média do brilho da vizinhança do pixel analisado, v o valor atual do seu brilho e os valores dos parâmetros utilizados foram escolhidos empiricamente.

Na Figura 28 é demonstrado a evolução dos valores de intensidade após aplicação da transformação logarítmica e os diferentes fatores de multiplicação calculados a partir da Equação 17. É possível constatar que os valores de intensidade menores sofreram uma mudança maior em relação aos de maiores intensidades e que os pixels que sofreram grandes mudanças de intensidade possuíam fatores de multiplicação mais altos.

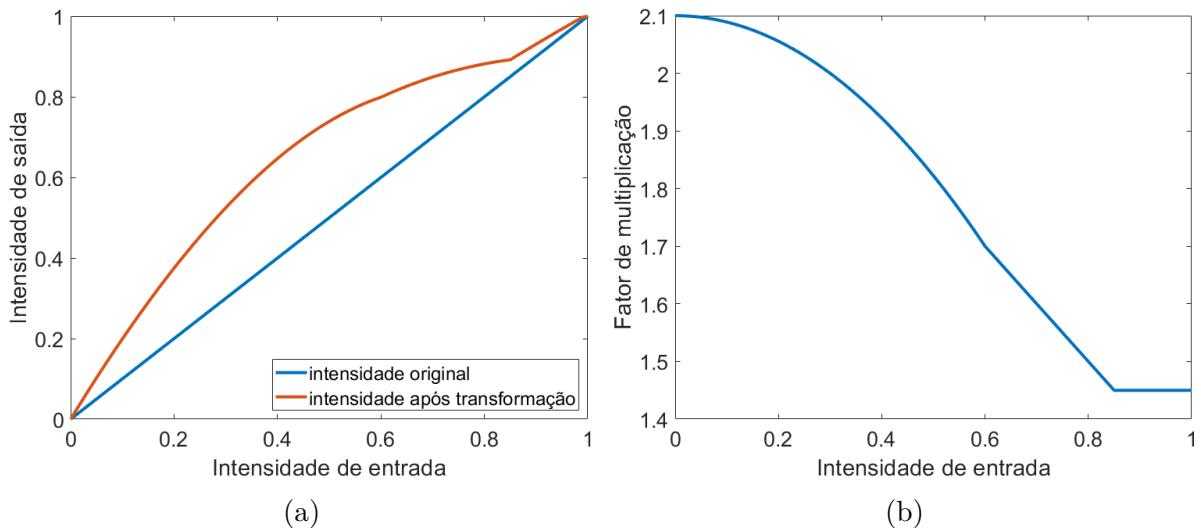


Figura 28 – Representação da evolução dos valores de intensidade em uma determinada imagem após a aplicação da transformação logarítmica com diferentes fatores de multiplicação. Em (a) é realizada uma comparação entre as intensidades originais e as mesmas após a transformação logarítmica e (b) corresponde aos valores dos diferentes fatores de multiplicação utilizados na imagem.

Algumas correções no histograma relacionadas a propriedade de brilho também foram necessárias. A primeira delas foi o deslocamento da média de brilho da imagem para 0.85.

Isso foi feito para que os valores de brilho fiquem o mais uniforme possíveis, mantendo um alto nível de intensidade e consequentemente possibilitando uma melhor visualização. A forma como foi realizado esse deslocamento é demonstrado na Equação 18:

$$b = b - (m - 0.85) \quad (18)$$

onde $b \in [0, 1]$ corresponde a propriedade de brilho do modelo *HSV* de um determinado ponto da imagem e m corresponde a média de brilho da mesma.

De modo a melhorar o contraste da imagem, também foi feita a equalização de parte do histograma do brilho da imagem. Com essa técnica a faixa de intensidades disponíveis no histograma é modificada e os seus valores são redistribuídos uniformemente entre os novos limites inferiores e superiores. Essa técnica não foi aplicada em todo o histograma, apenas em uma parte dos seus valores. Assim, pixels com intensidade de brilho no intervalo $[0.7, 0.95]$ foram redistribuídos para o intervalo $[0.6, 0.95]$, enquanto o restante dos valores permaneceu inalterado. Isso permitiu uma melhor distribuição dos níveis de brilho, obtendo assim uma iluminação mais uniforme e melhor contraste. Dessa forma, as regiões de interesse da imagem podem ser melhores visualizadas. Na Figura 29 é possível observar o histograma de uma determinada imagem antes e depois das alterações mencionadas. Os valores dos parâmetros utilizados para manipular o histograma foram escolhidos após a realização de vários testes, onde diferentes valores foram analisados.

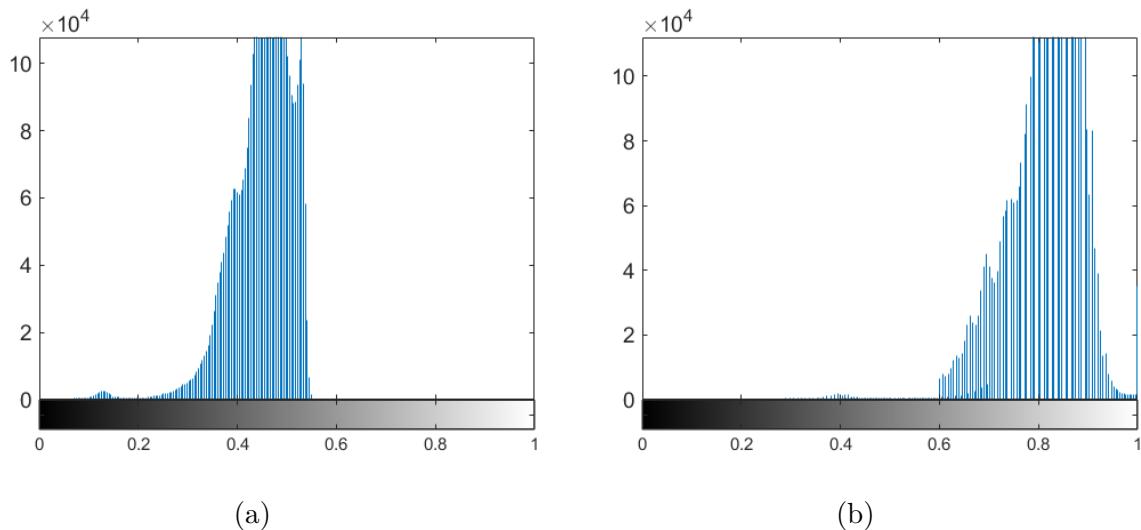


Figura 29 – Histogramas representando o antes e depois das alterações de brilho, onde (a) representa o histograma da imagem original e (b) o histograma após as aplicações das técnicas de deslocamento da média, expansão de brilho e transformação logarítmica.

Na Figura 30 é possível observar duas comparações entre imagens originais e os seus respectivos resultados após a aplicação das técnicas de correção de brilho. Ao analisar as imagens é possível constatar mudanças significativas nas suas propriedades de iluminação e contraste.

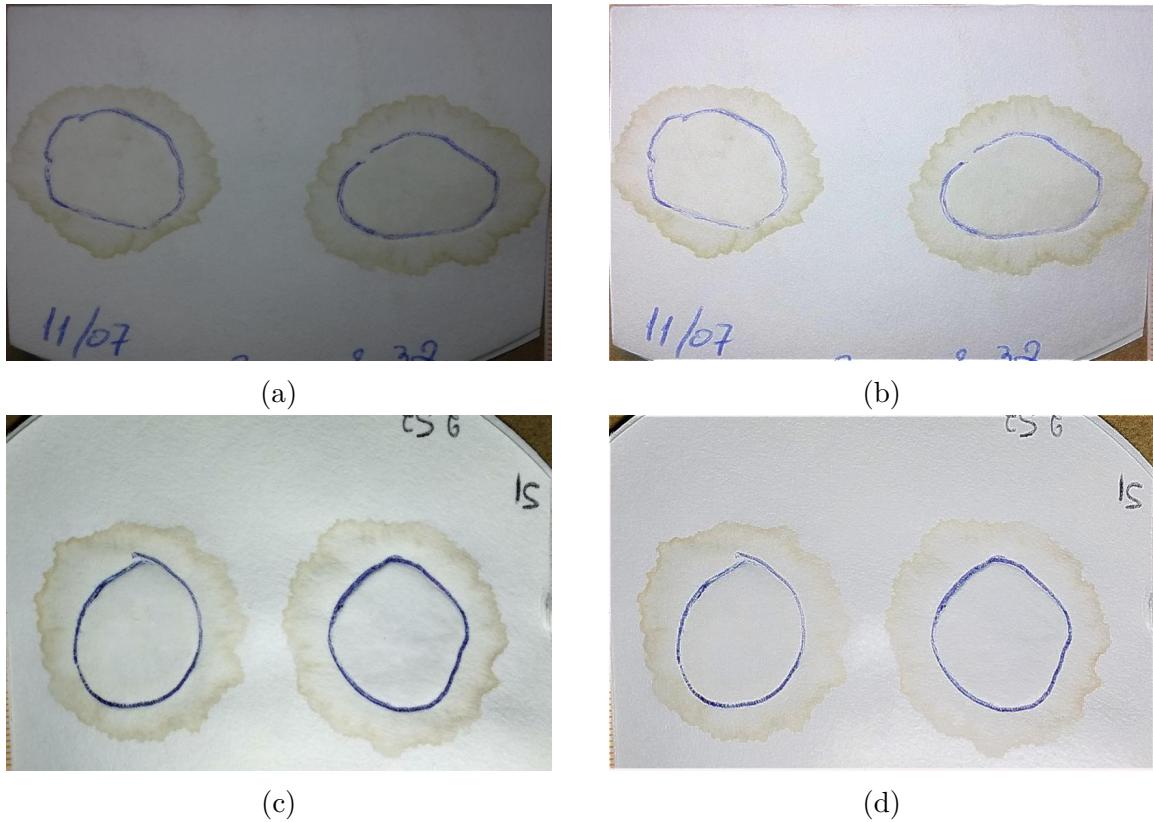


Figura 30 – Exemplos da aplicação das técnicas de correção de brilho, onde (a) e (c) são imagens originais com regiões de diferentes intensidades de brilho e (b) e (d) os seus respectivos resultados após a correção.

Após a correção da iluminação, a próxima ação necessária foi a normalização das cores. Ao longo do trabalho notou-se que em algumas imagens as médias dos canais *RGB* variavam em relação aos demais canais. Desse modo, dependendo do canal, as imagens poderiam apresentar aspectos azulados, esverdeados ou avermelhados. Para resolver esse problema, todos os canais *RGB* da imagem são verificados e, caso necessário, corrigidos. As correções são aplicadas conforme as Equações 19, 20 e 21:

$$R(x, y) = R(x, y) - (\bar{R} - \bar{G}), \quad \text{if } \bar{R} > \bar{G} \quad (19)$$

$$G(x, y) = G(x, y) - (\bar{G} - \bar{R}), \quad \text{if } \bar{G} > \bar{R} \quad (20)$$

$$B(x, y) = B(x, y) - (\bar{B} - \bar{G}), \quad \text{if } \bar{B} > \bar{G} \quad (21)$$

onde (x, y) é um determinado pixel; $R(x, y)$, $G(x, y)$ e $B(x, y)$ correspondem aos canais *R*, *G* e *B* do modelo de cores *RGB*; \bar{R} , \bar{G} e \bar{B} são as médias de intensidade dos seus respectivos canais.

Na Figura 31 é possível observar o resultado da normalização dos canais *RGB* em uma imagem com tons esverdeados.

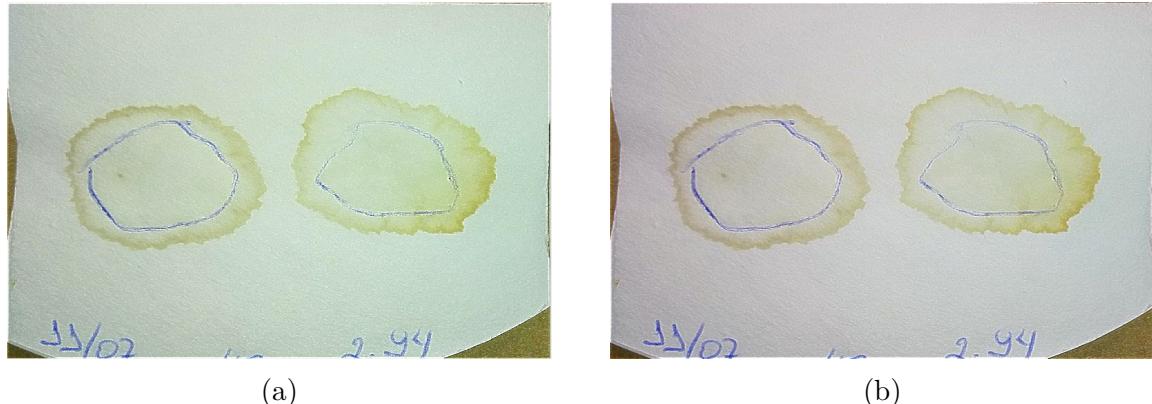


Figura 31 – Representação da aplicação da técnica de correção dos canais *RGB*, onde (a) corresponde a uma imagem com o canal *G* desbalanceado e (b) o resultado após a correção do canal *G*.

3.4 Segmentação da Área Externa

Com a imagem já preparada e com as devidas correções de iluminação feitas, o próximo passo é a segmentação da área externa. O principal objetivo dessa etapa é identificar e segmentar as regiões correspondentes às áreas totais (ou externas) de cada amostra da imagem permitindo que posteriormente sua área possa ser quantificada e utilizada no cálculo de CRA. Outro ponto interessante é que com as regiões externas segmentadas é possível criar máscaras a fim de facilitar o trabalho da etapa de segmentação interna.

Ao analisarmos as imagens constatamos que na maioria dos casos a coloração das bordas das amostras é formada por um tom de amarelo muito suave. Porém, em algumas regiões o tom da amostra e o branco do papel são muito similares. Sendo assim, o processo de limiarização se torna muito mais difícil devido a grande dificuldade de distinguir entre essas regiões, prejudicando a qualidade da segmentação. Visando melhorar esse cenário, foi aplicada uma técnica de realce de contraste visando aumentar o contraste entre as cores amarelas (que é o tom predominante da região da borda externa) e branca. O objetivo é realçar o máximo possível as regiões das amostras em amarelo para que essas áreas tenham uma coloração mais intensa. Desse modo, o contraste entre o branco do papel e o amarelo da amostra será maior, facilitando assim a distinção entre essas regiões.

No modelo de cores *RGB* a cor secundária amarela é criada a partir da junção das cores primárias vermelho (*R*) e verde (*G*). Consequentemente, o nível de azul (*B*) em uma região de tom amarelo deverá ser sempre menor do que os outros dois canais *R* e *G*. Ou seja, quanto menor for o valor do canal *B* em relação aos demais canais *R* e *G*, mais intensa será a cor amarela (GONZALEZ; WOODS, 2008). Sabendo-se disso, o objetivo da técnica é verificar as regiões da imagem onde o valor do canal *B* seja menor do que os demais e, uma vez encontrado, aumentar essa diferença. Dessa forma, os tons amarelos da imagem original serão realçados (principalmente nas bordas das amostras onde o amarelo é um pouco mais intenso). Com a aplicação dessa técnica é possível obter uma melhor

diferenciação entre o branco do filtro de papel e as amostras e consequentemente facilitar o processo de limiarização.

Antes da aplicação da técnica de realce é importante suavizar a imagem para que possíveis pequenos ruídos também não sejam realçados. Para isso é aplicado um filtro de suavização em formato de disco de raio igual a 10 pixels. Após a suavização o realce é aplicado conforme as Equações 22, 23 e 24:

$$B(x, y) = B(x, y) + 5 * d, \text{ se } |d| < 4.5 \quad (22)$$

$$d = B(x, y) - m \quad (23)$$

$$m = (R(x, y) + G(x, y))/2 \quad (24)$$

onde R , G e B correspondem, respectivamente, aos seus canais vermelho, verde e azul do modelo de cores RGB ; e os valores das constantes escolhidas foram as que produziram melhores resultados durante os experimentos.

Na Figura 32 é apresentado um exemplo da aplicação da técnica de realce de contraste.



Figura 32 – Representação da aplicação da técnica de realce de contraste, onde (a) corresponde a uma imagem original e (b) o resultado após o realce do amarelo.

De posse das amostras realçadas, o próximo passo é o processo de limiarização. O objetivo dessa etapa é segmentar as regiões das amostras por meio da comparação de um limiar. A ideia é criar uma imagem que contenha a princípio apenas duas classes. Para isso, valores acima de um determinado limiar são considerados como objetos (amostras de carne) e recebem valor igual a 1. Pixels cujas intensidades são menores que esse limiar são considerados como pertencentes ao fundo e recebem valor igual a 0.

Para que as bordas amarelas das amostras possam ser identificadas, os canais RGB precisam ser analisados. Regiões onde a diferença entre o canal G e B são maiores ou iguais a um certo limiar são consideradas como objeto, caso contrário essas regiões são classificadas como fundo. Na Equação 25 é possível observar a regra do processo de limiarização:

$$I(x, y) = \begin{cases} 1, & \text{se } G(x, y) - B(x, y) \geq limiar \\ 0, & \text{se } G(x, y) - B(x, y) < limiar \end{cases} \quad (25)$$

onde G e B representam os canais verde e azul do *RGB*, *limiar* corresponde ao respectivo limiar calculado e I é a imagem resultante.

As regras do cálculo do limiar foram determinadas empiricamente e são apresentadas nas Equações 26 e 27:

$$limiar = \begin{cases} round(meGB * 0.7), & \text{se } (meGB * 0.7) \leq 6 \\ 7, & \text{se } (meGB * 0.7) > 6 \end{cases} \quad (26)$$

sendo

$$meGB = \frac{1}{N * M} \sum_{x=1}^N \sum_{y=1}^M (G(x, y) - B(x, y)) \quad (27)$$

onde cada canal varia entre 0 e 255, o termo *round* representa a função de arredondamento para o inteiro mais próximo e *limiar* corresponde ao resultado.

Apenas a limiarização não é capaz de segmentar toda a amostra por completo. Sendo assim, foi necessário utilizar algumas operações morfológicas capazes de melhorar o resultado da limiarização e eliminar objetos que não pertencem às amostras.

A primeira das operações morfológicas utilizada foi a operação de fechamento. O objetivo do fechamento é unir as regiões das amostras que estão muito próximas umas das outras, de modo que toda a sua borda possa ser segmentada. Para essa operação foi utilizado como elemento estruturante no formato de disco com raio igual a 20 pixels.

Com as bordas das amostras completamente fechadas foi realizado o preenchimento de regiões. Até o momento, somente as bordas das amostras estão segmentadas, todo o seu interior é formado por pixels de intensidade igual a 0, formando um aspecto de buraco. A operação de preenchimento de regiões é capaz de preencher toda essa área, desde que a borda esteja completamente fechada. Desse modo, toda a área correspondente à amostra pode ser identificada e não somente às bordas. Na Figura 33 é possível observar as fases da segmentação da área externa mencionadas até o momento.

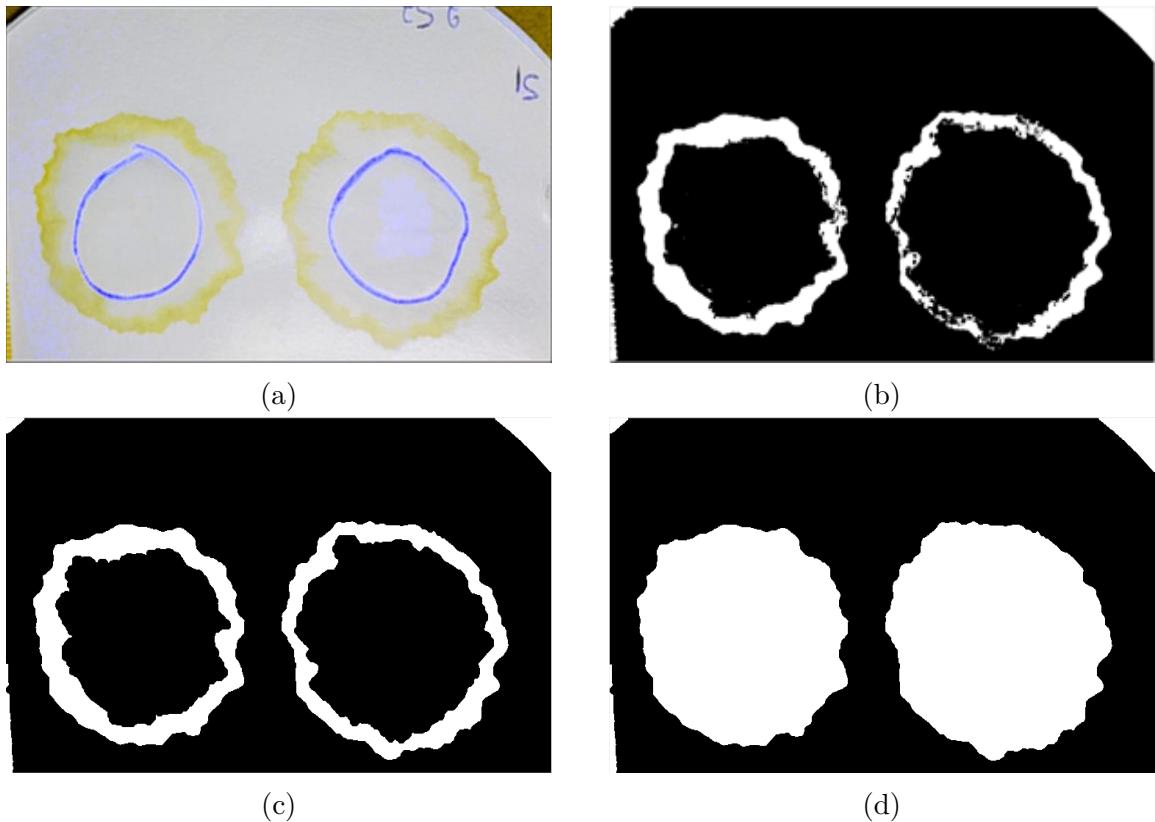


Figura 33 – Representação de algumas das etapas da segmentação da área externa, onde (a) corresponde à imagem original após o realce do amarelo, (b) a mesma após a limiarização, (c) a operação de fechamento e (d) o preenchimento de regiões.

O passo seguinte é responsável por eliminar outros possíveis objetos que não pertencem as amostras mas que pela semelhança de intensidade também foram segmentados. Vários fatores podem justificar o surgimento desses objetos, como por exemplo a coloração do filtro de papel, marcações realizadas a caneta pelo profissional especialista e, principalmente, a presença de pequenas áreas remanescentes do fundo da imagem. Mesmo após a realização do recorte de fundo, algumas pequenas regiões de fundo acabam permanecendo em certas imagens, principalmente nas regiões laterais e nos cantos da imagem.

Para resolver esse problema, primeiramente foi utilizada a operação morfológica de componentes conexos. Como em cada imagem há sempre duas amostras e elas são os maiores objetos da imagem, o objetivo é utilizar a técnica de componentes conexos para identificar e manter somente os dois maiores objetos. A partir da análise de conectividade dos pixels, todos os objetos são identificados e seus pixels são contabilizados. Somente os dois maiores são mantidos.

Em alguns casos as amostras não estão inseridas na região central do filtro de papel. Também há a possibilidade de parte delas estarem muito próximas às laterais e à regiões do fundo que não foram recortadas por completo. Dessa forma, há a possibilidade de regiões do fundo serem confundidas com amostras e serem segmentadas como um só

objeto. Para resolver esses casos foi necessário modificar as margens em todas as laterais da imagem. A ideia é fazer com que todos os pixels das 40 primeiras e 40 últimas linhas e colunas pertençam ao fundo, ou seja, tenham valor igual a 0. Na Figura 34 é possível observar o processo de eliminação de falsos positivos.

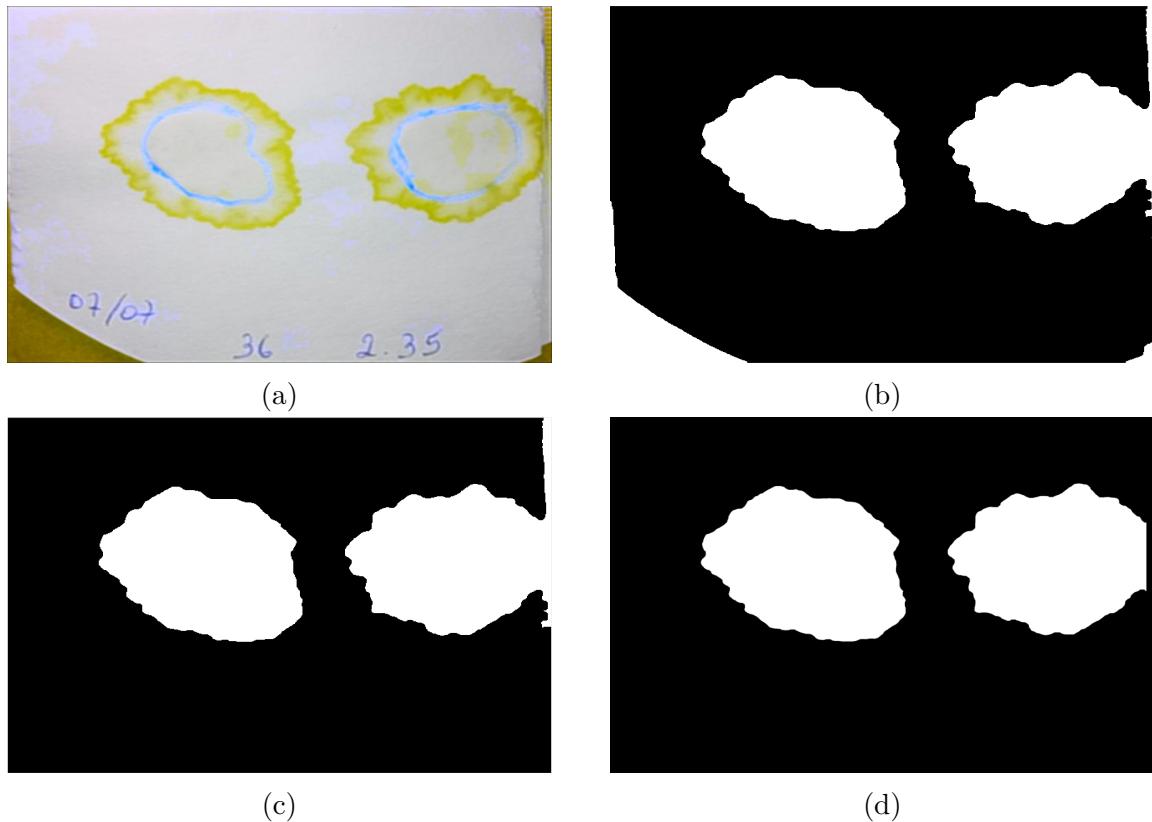


Figura 34 – Representação do processo de eliminação de falsos positivos, onde (a) representa a imagem original após o realce do amarelo, (b) a mesma após a limiarização, (c) a eliminação de falsos positivos pela operação de componentes conexos e (d) o resultado após a aplicação das margens laterais.

Em algumas imagens constatamos que as amostras estavam tão próximas umas das outras que suas regiões se tocavam. Dessa forma, era praticamente impossível distinguir visualmente os limites de cada amostra, o que acabaria prejudicando os resultados da etapa de segmentação. Na maioria desses casos isso pode ser justificado pela junção de dois fatores, a proximidade com que as amostras são colocadas sobre o filtro de papel e a elevada quantidade de água retida dentro de cada uma das amostras. Neste caso utilizamos o algoritmo de agrupamento *K-means*, para separar as amostras. O conjunto de dados de entrada são as coordenadas dos pixels que compõem o componente conexo. A quantidade de classes (valor de k) equivale ao número de amostras, portanto sempre existirão apenas 2 classes e consequentemente 2 centróides para cada imagem.

A execução do *K-means* é necessária apenas quando há amostras com regiões interligadas. Sendo assim, foi preciso criar uma regra para que essa técnica seja aplicada somente em casos específicos. Com a imagem já segmentada, a quantidade de pixels dos dois

maiores componentes conexos é analisada. Geralmente as áreas das amostras são bem maiores do que as regiões remanescentes do fundo, principalmente quando duas amostras estão interligadas. Nesse último caso, o maior objeto normalmente possui pelo menos 10 vezes o tamanho do segundo maior objeto da imagem. Sabendo-se disso, o *K-means* é executado exclusivamente em imagens onde a quantidade de pixels do maior componente conexo é 10 vezes maior do que a do segundo maior objeto. Neste caso, apenas o maior componente conexo é mantido e o *K-means* é executado.

Na Figura 35 é possível observar uma ilustração do processo de execução do algoritmo *K-means* em uma imagem de amostras com regiões sobrepostas.

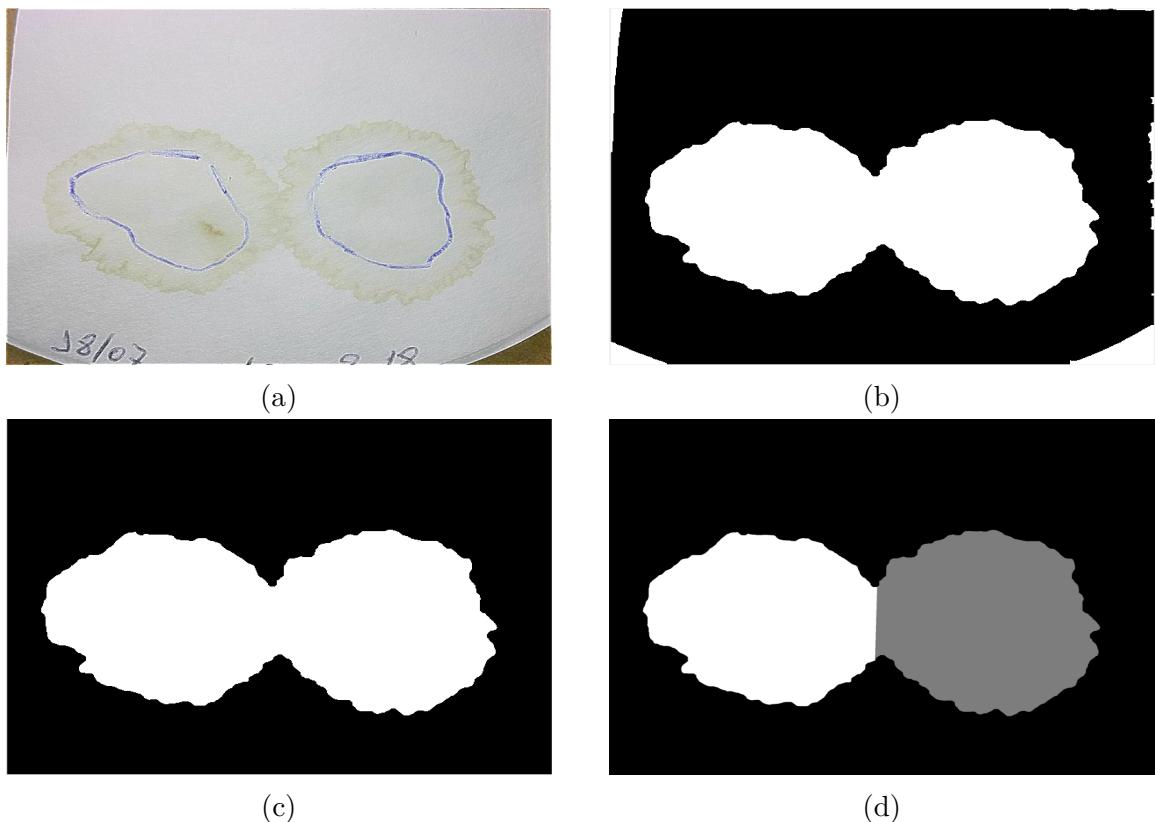


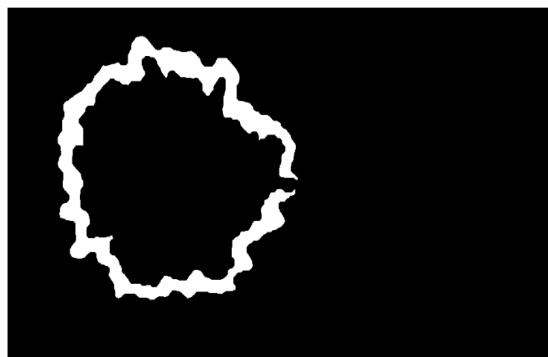
Figura 35 – Representação da execução do algoritmo de agrupamento *K-means*, onde (a) representa a imagem original após a correção de iluminação, (b) a mesma após a etapa de limiarização, (c) o maior componente conexo da imagem e (d) o resultado após a segmentação pelo *K-means*.

A última tarefa da etapa de segmentação da área externa é responsável por ligar e preencher as regiões das amostras que não puderam ser totalmente segmentadas. Mesmo após a aplicação da operação morfológica de fechamento, algumas amostras não conseguem ter suas bordas identificadas por completo e, consequentemente, o seu interior também não é preenchido. Normalmente isso é justificado pela semelhança de intensidade entre as regiões do filtro de papel e as amostras, fazendo com que em alguns casos o método proposto não consiga criar um limiar capaz de segmentar perfeitamente essas regiões.

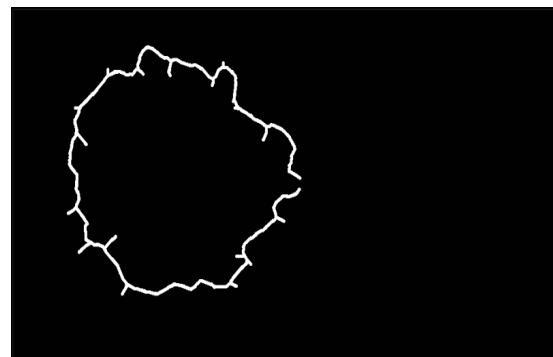
A estratégia para resolver esses casos foi identificar os pontos extremos da borda de cada uma dessas amostras e traçar uma linha ligando esses pontos. Ao ligar esses extremos, a borda da amostra estará completamente fechada, permitindo assim que todo o seu interior possa ser preenchido e com isso a área da amostra possa ser segmentada da forma mais aproximada possível.

Assim como no caso do *K-means*, essa tarefa apenas é executada em situações específicas, exclusivamente em casos onde pelo menos uma das amostras não tenha sido totalmente segmentada. Sendo assim, com a imagem contendo apenas os dois maiores componentes conexos, o tamanho de cada um desses objetos é novamente verificado. Normalmente, o objeto de uma amostra completamente segmentada possui uma quantidade de pixels muito mais elevada do que a de uma outra que não foi totalmente segmentada, principalmente pelo fato dessas amostras não terem os seus interiores preenchidos. Sabendo-se disso, a técnica de detecção de pontos extremos apenas será executada em casos onde a quantidade de pixels do objeto analisado for menor do que 7.5% da imagem.

O processo de identificação dos pontos extremos começa com a aplicação da operação morfológica de esqueletização. Com essa técnica é possível diminuir a quantidade de informações dos objetos de interesse sem que as suas características topológicas essenciais sejam perdidas. O objeto correspondente à amostra passa a ser uma versão simplificada (como um esqueleto), contendo apenas finas linhas correspondentes a sua estrutura essencial. Na Figura 36 é possível observar uma comparação entre uma amostra não segmentada por completo e o seu respectivo esqueleto. É possível constatar que houve uma grande diminuição do número de pixels referentes ao objeto da imagem.



(a)



(b)

Figura 36 – Comparação do processo de esqueletização, onde (a) representa uma amostra segmentada e (b) o seu esqueleto.

A partir da análise da vizinhança dos pixels é possível determinar os tipos de pontos de um esqueleto. Para ser considerado um ponto extremo o pixel deve possuir menos de dois vizinhos; caso ele possua exatamente dois, o pixel é pertencente a um ponto interior (ou linha) e caso ele possua mais de dois vizinhos, é denominado como ponto de junção (ANDREZZA, 2015). Esses pontos são importantes para se descobrir informações sobre

a estrutura topológica do objeto. Na Figura 37 é possível observar o esqueleto de uma imagem e a identificação de alguns dos seus pontos.

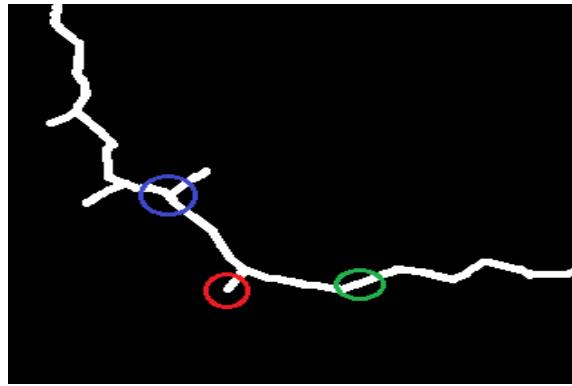


Figura 37 – Representação de alguns pontos de um determinado esqueleto, onde a marcação em vermelho representa um ponto extremo, em azul uma junção e em verde são pontos de linhas.

O esqueleto pode ser comparado a um grafo, onde cada pixel do esqueleto corresponde a um vértice e as arestas são conexões entre os pixels vizinhos (RUBERTO, 2004). Matematicamente, cada pixel de uma imagem $I(x,y)$ corresponde a um vértice $v \in V$ do grafo $G(V,A)$. Uma aresta $a \in A$ desse mesmo grafo estará conectada a dois vértices somente se a distância Chebyshev entre eles for menor ou igual a 1, conforme demonstrado na Equação 28:

$$A = \{(v, v') \in V \times V | \max(|x - x'|, |y - y'|) \leq 1\} \quad (28)$$

sendo x e y as coordenadas do pixel $I(x,y)$; V e A os conjuntos de vértices e arestas do grafo $G(V,A)$ (JUNIOR et al., 2017).

Os vértices foram identificados a partir da utilização da transformação morfológica de acerto ou erro (*Hit or Miss*). Essa operação é responsável por encontrar padrões entre os pixels locais da imagem, onde um elemento estruturante é utilizado como referência. Ao usar essa técnica, apenas os pixels que cuja vizinhança representa a forma de algum elemento estruturante são mantidos (SONKA; HLAVAC; BOYLE, 2008). Para isso, foram utilizados vários elementos estruturantes no formato de janela de tamanho 3×3 com valores positivos e negativos de peso igual a 1. Essas janelas representam as possíveis formas dos pontos da imagem, sendo que os valores positivos representam pixels do objeto e os negativos correspondem ao fundo.

Com os pontos do esqueleto devidamente identificados é possível calcular a distância entre os vértices e com isso determinar quais são os dois pontos extremos mais distantes. O algoritmo do menor caminho (ou algoritmo de Dijkstra) é o responsável por calcular a distância entre cada um dos vértices. O custo de deslocamento entre um vértice a outro é determinado pela quantidade de arestas entre eles, no caso a quantidade de pixels. Em sequência, a distância entre cada ponto extremo e os demais é verificada e são escolhidos

os dois pontos extremos mais distantes, ou seja, os que possuem o maior caminho entre um ponto ao outro.

Após identificar os pontos extremos mais distantes, o próximo passo é traçar uma linha unindo esses pontos na imagem segmentada. Isso permite fechar a borda da amostra por completo, possibilitando assim que toda a sua região interior possa ser preenchida. Fazendo isso, a segmentação da área externa estará finalizada. Na Figura 38 é possível observar todo o processo de preenchimento e ligação dos pontos extremos.

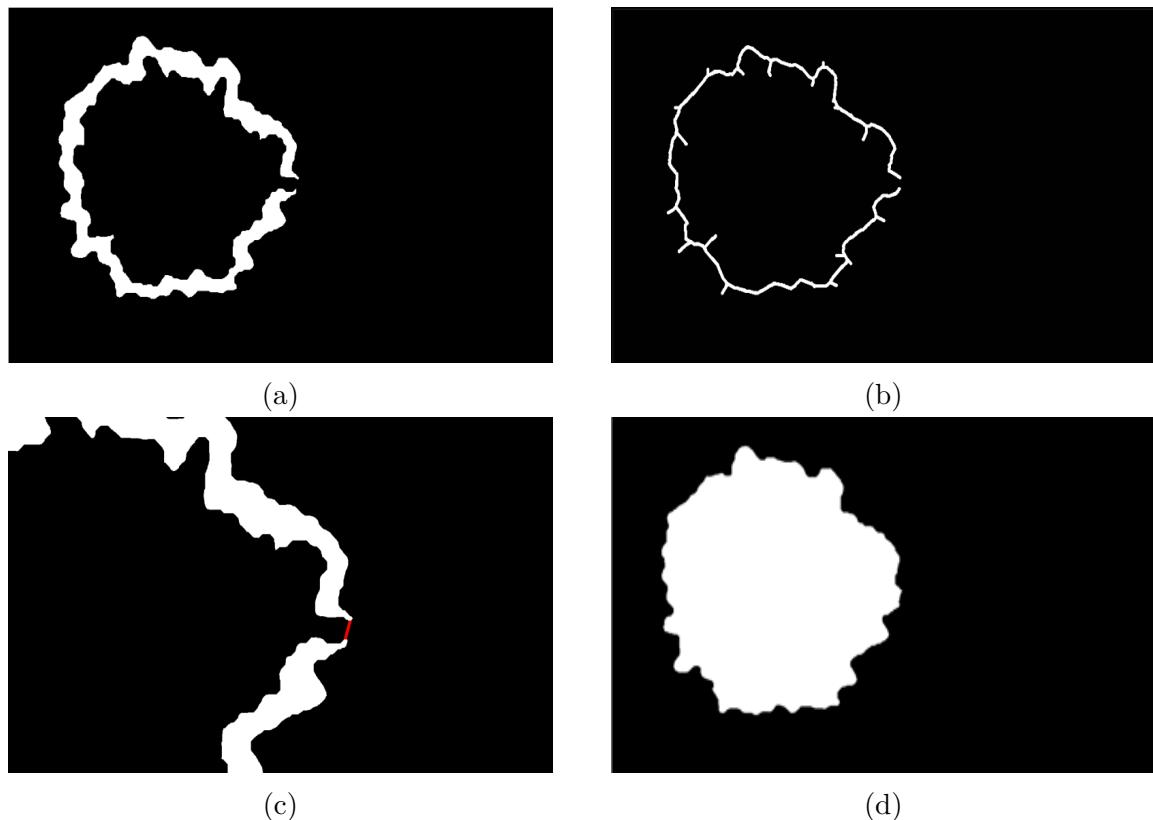


Figura 38 – Representação do processo de preenchimento e detecção de pontos extremos, onde (a) representa a segmentação incompleta de uma amostra, (b) o seu esqueleto, (c) a mesma imagem ampliada com a ligação dos pontos extremos em vermelho e (d) o resultado da técnica.

3.5 Segmentação da Área Interna

Com a área externa já segmentada o próximo passo é a etapa de segmentação da área interna. O objetivo dessa fase é identificar as marcações realizadas à caneta pelos profissionais especialistas no centro de cada amostra. Essas regiões a serem segmentadas correspondem às áreas das porções de carne utilizadas durante a aplicação da técnica de CRA por compressão. Ao término do processo de segmentação interna é possível comparar as duas regiões segmentadas de cada amostra (área externa e interna) e como isso calcular a CRA de cada uma delas.

Conforme mencionado anteriormente, um dos principais motivos de começar com a segmentação da região externa é que com a identificação total da amostra o trabalho da segmentação interna é facilitado. Isso acontece porque as marcações são sempre realizadas na região central de cada amostra e como as regiões externas já foram segmentadas, suas áreas podem servir como máscara de referência para identificação da área interna. Dessa forma não é preciso ser preocupar com possíveis falsos positivos localizados fora das regiões das amostras.

Para que isso seja possível, a máscara da segmentação externa é multiplicada pela imagem original já preparada. Como a máscara possui somente duas intensidades diferentes (0,1), apenas regiões da imagem original multiplicadas por pixels iguais a 1 mantêm as suas intensidades originais, todo o restante passa ser composto apenas por pixels de intensidade igual a 0, conforme demonstrado na Equação 29:

$$R = I * M \quad (29)$$

onde I corresponde a imagem preparada, M a máscara das amostras segmentadas e R a imagem filtrada. Na Figura 39 é possível observar um exemplo da aplicação da segmentação das áreas externas.

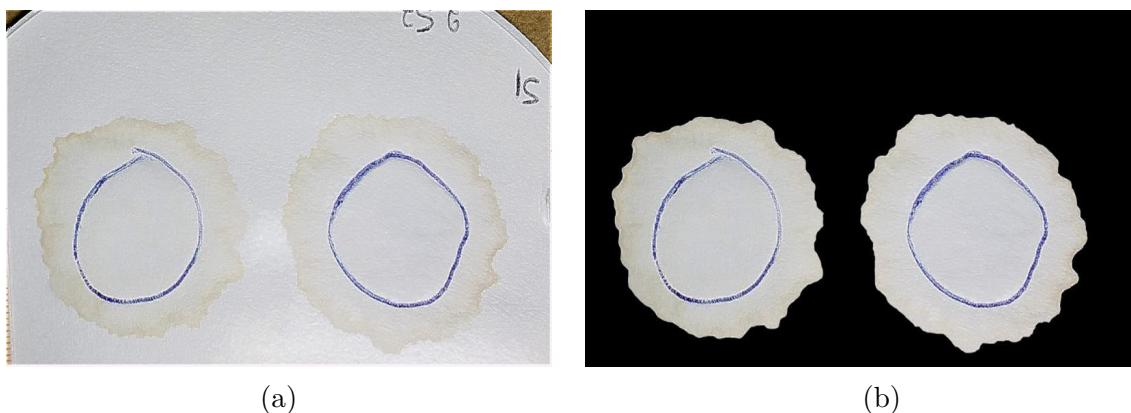


Figura 39 – Representação do processo de recorte das áreas externas, onde (a) corresponde a imagem original e (b) o resultado da segmentação.

Com o fundo completamente removido o próximo passo é o processo de limiarização, responsável por segmentar as marcações feitas à caneta. Ao analisarmos o conjunto de imagens observamos que os profissionais responsáveis fizeram as marcações com canetas de diferentes cores: azul, verde, vermelho e preto. Desse modo, apenas um limiar não seria capaz de distinguir todas as regiões de interesse do restante da imagem. Sendo assim, foi necessário criar um limiar para cada característica relevante da imagem, como por exemplo, a diferença entre certos canais do *RGB*, níveis do brilho e saturação. Para cada cor de caneta, diferentes características foram analisadas. Na Figura 40 é possível observar imagens com os quatro tipos de cores encontradas.

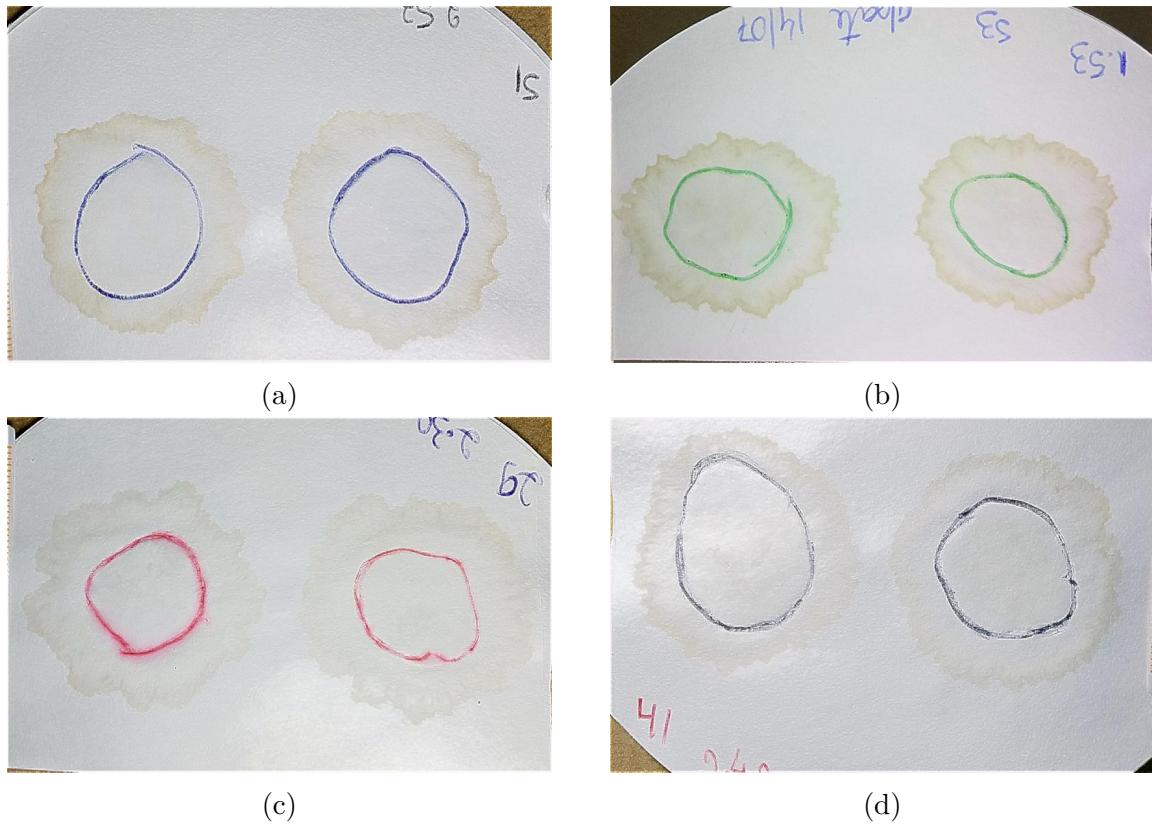


Figura 40 – Representação das marcações feitas por canetas de diferentes cores, onde (a) representa a cor azul, (b) verde, (c) vermelha e (d) preta.

Na Equação 30 é demonstrado o conjunto de condições utilizadas para segmentar as marcações feitas pelos quatro tipos de cores de caneta, na seguinte ordem: azul, verde, vermelha e preta. Os valores dos limiares são formados por constantes nas quais foram escolhidas após a realização de diversos testes e ajustes.

$$I(x, y) = \begin{cases} 1, & \text{se } B(x, y) - G(x, y) \geq 7 \quad \& \quad s(x, y) \geq 0.06 \quad \& \quad v(x, y) \leq 0.75 \\ 1, & \text{se } G(x, y) - R(x, y) \geq 15 \quad \& \quad s(x, y) \geq 0.06 \quad \& \quad v(x, y) \leq 0.7 \\ 1, & \text{se } R(x, y) - G(x, y) \geq 20 \\ 1, & \quad \quad \quad \text{se } v(x, y) > 0.3 \quad \& \quad v(x, y) \leq 0.6 \quad \& \quad s(x, y) < 0.06 \\ 0, & \quad \quad \quad \text{caso contrário} \end{cases} \quad (30)$$

onde R , G e B , variando entre 0 e 255, representam os respectivos canais vermelho, verde e azul do modelo de cores RGB ; v e s , variando entre 0 e 1, correspondem ao brilho e a saturação do modelo HSV e I é a imagem resultante da limiarização.

Em alguns casos, a limiarização gera pequenos objetos não pertencentes às áreas demarcadas. Nestes casos, esses objetos precisam ser eliminados para que o resultado final da segmentação não seja afetado. Normalmente, esses pequenos objetos aparecem nas extremidades das amostras. Isso se deve a semelhanças de intensidades entre as suas

regiões e as áreas demarcadas. Sabendo-se disso, a estratégia para eliminar esses objetos indesejados foi primeiramente aplicar na máscara de segmentação externa uma operação de erosão com elemento estruturante no formato de disco de tamanho igual a 20 pixels. Em seguida, as posições dos seus pixels iguais a 0 são salvas em um vetor e comparadas com as posições da imagem recém segmentada (limiarização da área interna). O objetivo é que todas as posições dessa nova imagem contidas no vetor passem a ser de pixels iguais a 0. Dessa maneira, as áreas correspondentes à amostras diminuem e todos os pequenos objetos presentes nas suas antigas extremidades desaparecem.

O próximo passo foi aplicar as operações morfológicas de fechamento e preenchimento de regiões. Semelhante a etapa de segmentação da área externa, o objetivo do fechamento é ligar as regiões das áreas demarcadas próximas umas das outras utilizando como elemento estruturante um disco de raio igual a 20 pixels. A técnica de preenchimento de regiões é responsável por preencher todo o interior das marcações totalmente fechadas para que assim toda a sua área possa ser completamente identificada. Na Figura 41 é possível observar as fases da segmentação da áreas interna mencionadas até o momento.

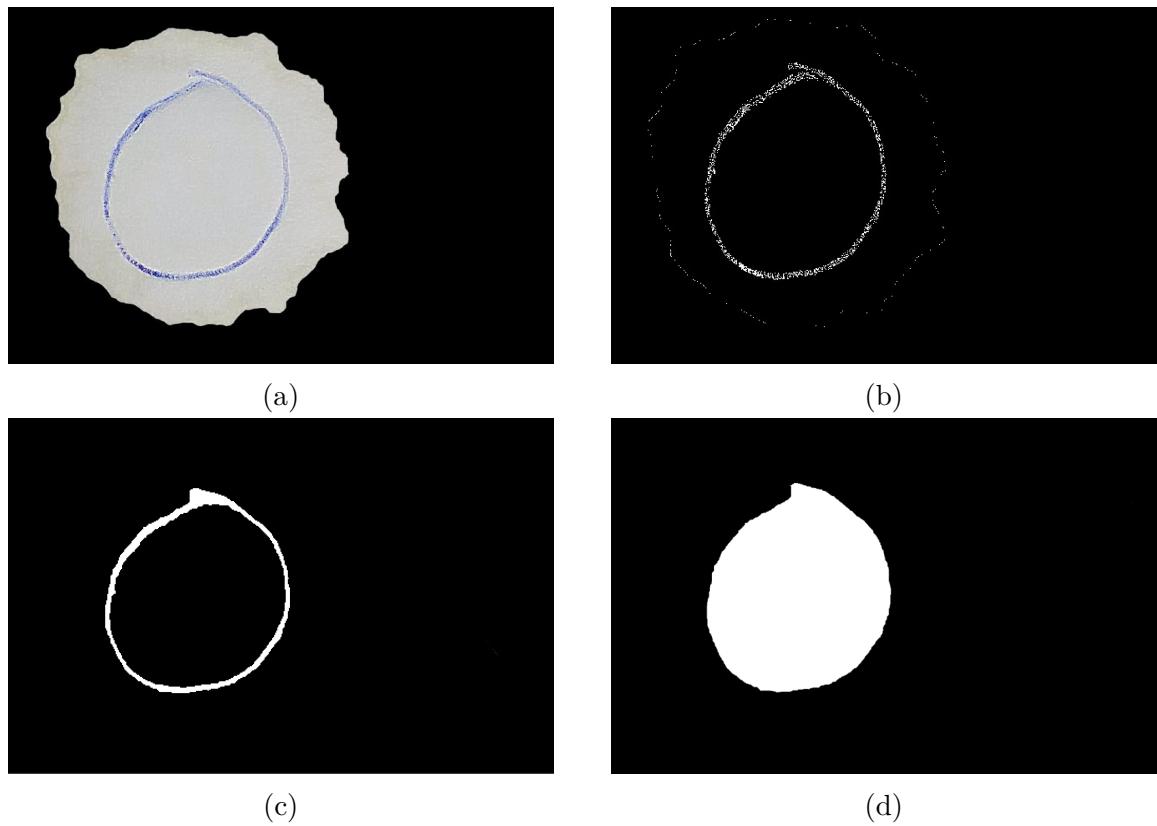


Figura 41 – Representação de algumas das etapas do processo de segmentação da área interna, onde (a) é a imagem original segmentada, (b) a mesma após a limiarização, (c) a remoção dos pequenos falsos positivos e aplicação da operação de fechamento e (d) o resultado após o preenchimento das regiões.

Assim como na segmentação da área externa, o último passo é responsável por ligar e preencher as regiões das marcações que por algum motivo não puderam ser totalmente

segmentadas. Isso se deve a possíveis falhas ocorridas durante o processo de demarcação das áreas e não apenas por semelhanças de intensidades. Ao contornar a porção de carne pode ocorrer da caneta falhar ou até mesmo que o profissional responsável não contorne o objeto por completo. Desse modo, as regiões demarcadas não ficam totalmente fechadas, o que acaba dificultando ainda mais o trabalho de segmentação. Na Figura 42 é apresentado um exemplo de amostra com essas características.



Figura 42 – Representação de amostras contendo falhas nas suas marcações.

Para resolver esse problema foi utilizado o processo de detecção de pontos extremos, semelhante ao aplicado na segmentação da área externa. A diferença é que nessa etapa há a possibilidade de existirem mais de um objeto de interesse por amostra. Nesses casos, as ligações devem ser realizadas entre os pontos extremos dos objetos mais próximos e não apenas nas próprias extremidades.

Antes de aplicar a técnica de esqueletização, primeiramente é necessário eliminar a presença de possíveis ruídos, excluindo todos os componentes conexos menores do que 40 pixels. Em seguida, é preciso verificar se as regiões demarcadas estão completamente segmentadas. Como em cada amostra pode haver vários objetos correspondentes a uma mesma marcação, apenas o tamanho dos dois maiores objetos da imagem não é capaz de constatar que as marcações foram totalmente segmentadas. Sendo assim, com o auxílio da máscara de segmentação da área externa é possível identificar as marcações de cada amostra, separadamente, e com isso verificar a quantidade de pixels dos seus objetos. A esqueletização apenas será aplicada quando a soma do número total de pixels dos objetos de interesse de cada amostra for menor do que 5% do tamanho total da imagem.

Após a esqueletização, o próximo passo é detectar os dois pontos extremos mais distantes entre si de cada objeto. Para isso, o algoritmo do menor caminho (algoritmo de Dijkstra) é executado separadamente em cada um dos grafos formados pelos esqueletos dos objetos. Caso exista apenas um objeto, uma linha é traçada entre os seus pontos extremos e em seguida o seu interior é preenchido. Caso contrário, todas as coordenadas dos pontos extremos mais distantes de cada objeto são armazenadas em uma lista. A partir do cálculo da distância euclidiana, os pontos dessa lista mais próximos uns dos outros

são ligados por meio de uma reta, desde que os pontos a serem ligados não pertençam ao mesmo objeto. Esse processo se repete até que todos os objetos estejam ligados e, consequentemente, a área demarcada esteja completamente fechada. Dessa maneira, todo o interior da área demarcada pode ser preenchido e com isso a segmentação da área interna é finalizada. Na Figura 43 é possível observar todo o processo de ligação e preenchimento das regiões internas.

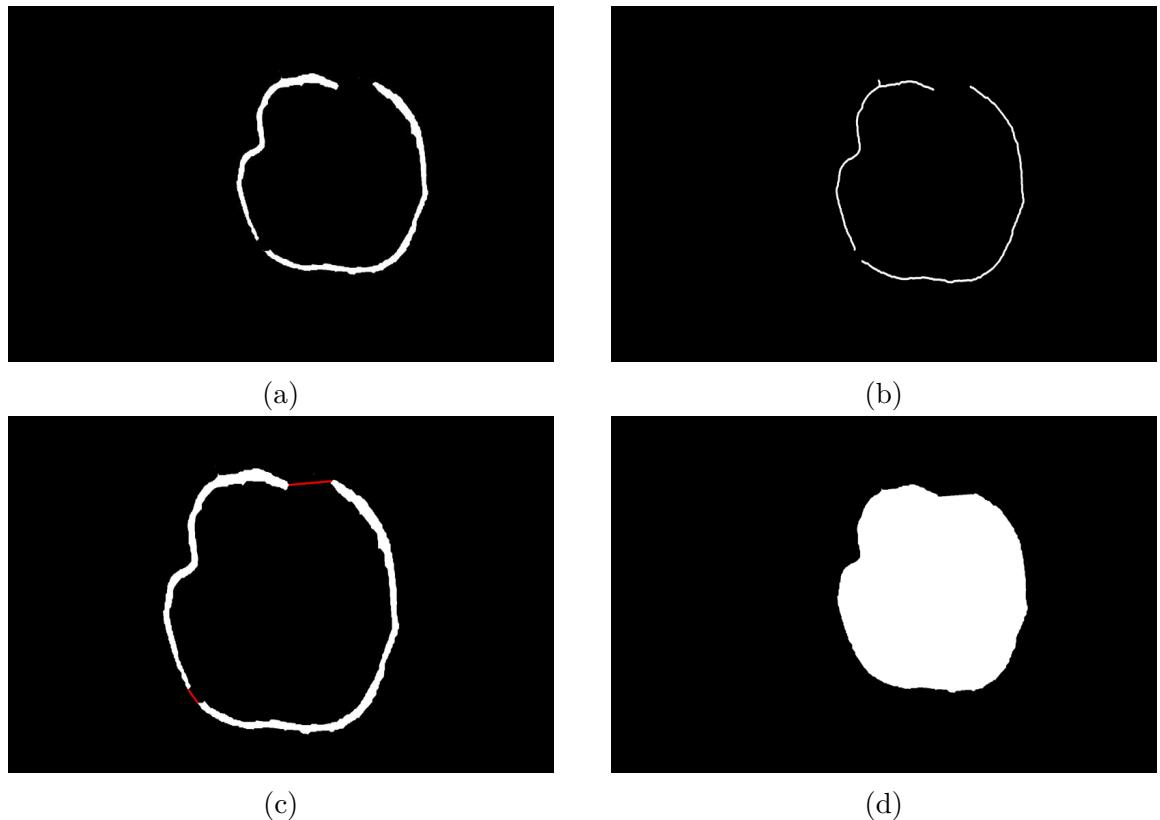


Figura 43 – Representação do processo de preenchimento e detecção de pontos extremos, onde (a) representa a segmentação incompleta das áreas demarcadas, (b) os esqueletos dos objetos de interesse, (c) a mesma ampliada contendo em destaque as ligações realizadas entre as extremidades dos objetos e (d) o resultado da técnica.

3.6 Cálculo das áreas e da CRA

O método de avaliação de CRA utilizado é responsável por quantificar cada uma das áreas segmentadas para que assim seja possível calcular a CRA de cada uma delas. Após o processo de segmentação, algumas informações como a quantidade de pixels das áreas internas e externas das amostras são extraídas. Para isso, as imagens resultantes das duas etapas de segmentação são analisadas e os seus pixels são identificados e contabilizados. Na Figura 44 é possível observar um exemplo de imagem segmentada com as suas respectivas áreas identificadas.

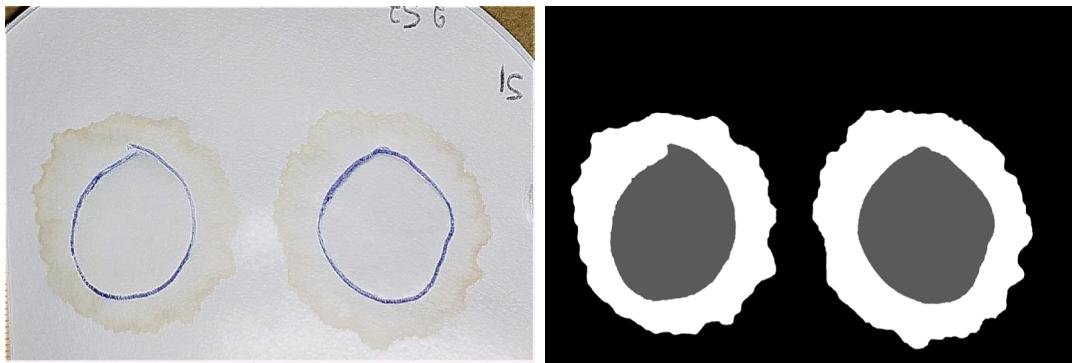


Figura 44 – Representação do processo de segmentação onde à esquerda está a imagem original e à direita a mesma com as suas regiões identificadas.

A CRA de uma amostra é calculada através da relação entre o tamanho da porção de carne prensada (área interna) e a região total da amostra (área externa). Com as regiões já quantificadas é possível calcular a CRA de cada amostra individualmente e também estabelecer uma média entre os valores de CRA das duas amostras da imagem. A CRA individual e o valor médio são calculados conforme as Equações 31 e 32:

$$CRA = area_{int}/area_{ext} \quad (31)$$

$$meCRA = (CRA_1 + CRA_2)/2 \quad (32)$$

onde CRA é a proporção entre as regiões de uma amostra; $area_{int}$ e $area_{ext}$ correspondem as quantidades de pixels das suas respectivas áreas internas e externas; CRA_1 representa a proporção da amostra esquerda e CRA_2 o valor da amostra da direita; e $meCRA$ a média entre as duas CRAs da imagem.

CAPÍTULO 4

Experimentos e Análise dos Resultados

Neste capítulo são apresentados os experimentos realizados utilizando as técnicas do método proposto, assim como o conjunto de imagens utilizado. Todos os resultados obtidos são apresentados e avaliados ao longo deste capítulo.

4.1 Dataset

Durante a realização deste trabalho foram utilizadas 665 imagens de amostras de carnes suínas obtidas a partir do método de compressão. Todas as imagens foram disponibilizadas pela pesquisadora Isaura Maria Ferreira do Programa de Pós-Graduação em Ciências Veterinárias da Universidade Federal de Uberlândia.

Com o objetivo de facilitar a realização dos experimentos, selecionamos apenas 16 imagens de todo o conjunto e criamos um pequeno subconjunto retratando as mais diferentes características das imagens presentes no dataset. Dentre essas características, podemos citar as variações dos níveis de iluminação da imagem; o tamanho, formato, capacidade de retenção de água, coloração e posicionamento das amostras; a cor da caneta utilizada para demarcar a região interna; entre outras. A ideia é aplicar as técnicas do método proposto primeiramente no subconjunto de imagens recém criado para que, somente depois de validadas, essas técnicas possam ser executadas em todo o conjunto.

4.2 Análise Experimental

Os primeiros experimentos foram realizados no subconjunto de imagens selecionadas do dataset. Todos eles foram executados seguindo as etapas do método proposto: preparação, correção da iluminação e segmentação das áreas externas e internas. Na medida em que as técnicas eram criadas e testadas, os primeiros resultados eram obtidos e avaliados. Vários ajustes foram necessários até que os resultados obtidos fossem considerados satisfatórios. Após os devidos ajustes e validações, outros experimentos foram realizados no restante das imagens do dataset.

Na etapa de preparação as imagens do subconjunto foram convertidas para o formato *PNG*, a posição de visualização das imagens foi padronizada e o fundo de cada uma delas foi recortado. Nessa etapa, todas as 16 imagens tiveram bons resultados conforme demonstrado na Figura45.



Figura 45 – Resultado da etapa de preparação aplicada no subconjunto de imagens selecionadas do dataset.

Como pode ser observado, em alguns casos o fundo não foi totalmente recortado, principalmente nas extremidades diagonais da imagem. Apesar disso, a presença dessas regiões não afetou o resultado da segmentação, pois essas áreas são removidas nos passos seguintes.

A etapa de correção da iluminação também obteve excelentes resultados. A partir dela, o brilho e os canais do *RGB* puderam ser corrigidos, gerando assim novas imagens onde as suas regiões de interesse são mais facilmente identificadas, como mostrado na Figura46. Em alguns casos, certas regiões da imagem que já possuíam um elevado nível de brilho (causadas principalmente pelo excesso de luz natural ou artificial) não sofreram grandes alterações como em outras partes da imagem. No entanto, como normalmente essas regiões pertencem às áreas do filtro de papel, essas irregularidades não afetaram a visualização das amostras, conforme demonstrado na Figura47.



Figura 46 – Resultado da etapa de correção da iluminação aplicada no subconjunto de imagens selecionadas do dataset.

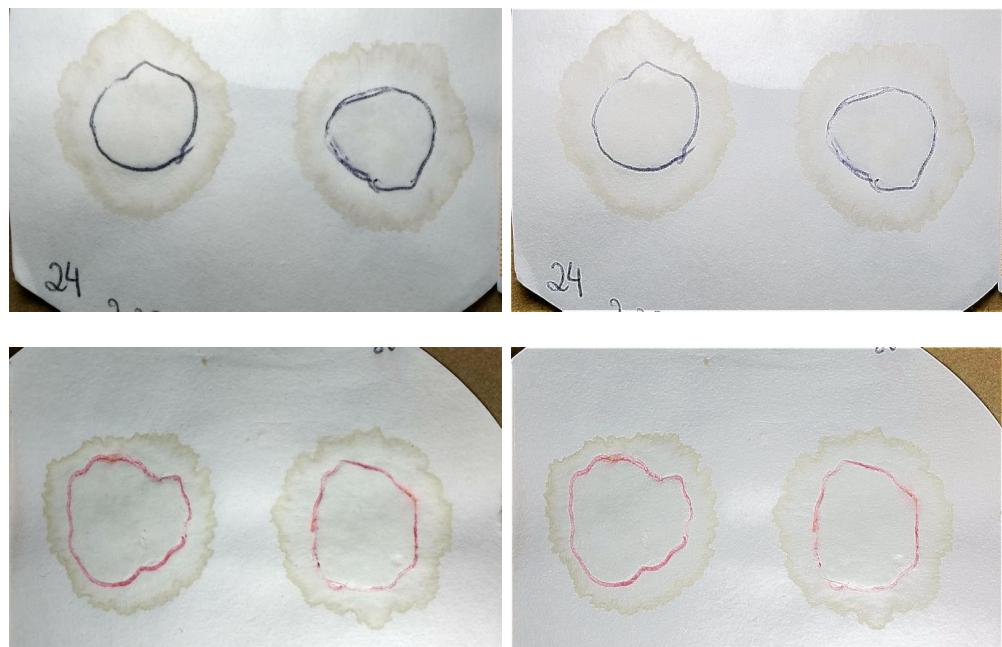


Figura 47 – Imagens do subconjunto que permaneceram com algumas irregularidades, onde à esquerda estão as originais e à direita o resultado da correção.

Durante as etapas de segmentação, o maior desafio foi estabelecer limiares capazes de diferenciar as amostras do restante da imagem. Após vários testes e ajustes, conseguimos alcançar resultados consideravelmente satisfatórios.

Na etapa de segmentação da área externa, praticamente todas as amostras do subconjunto de imagens puderam ser identificadas por completo, com exceção de duas amostras. Na Figura 48 é possível observar alguns dos casos da etapa de segmentação da área externa que obtiveram êxito.

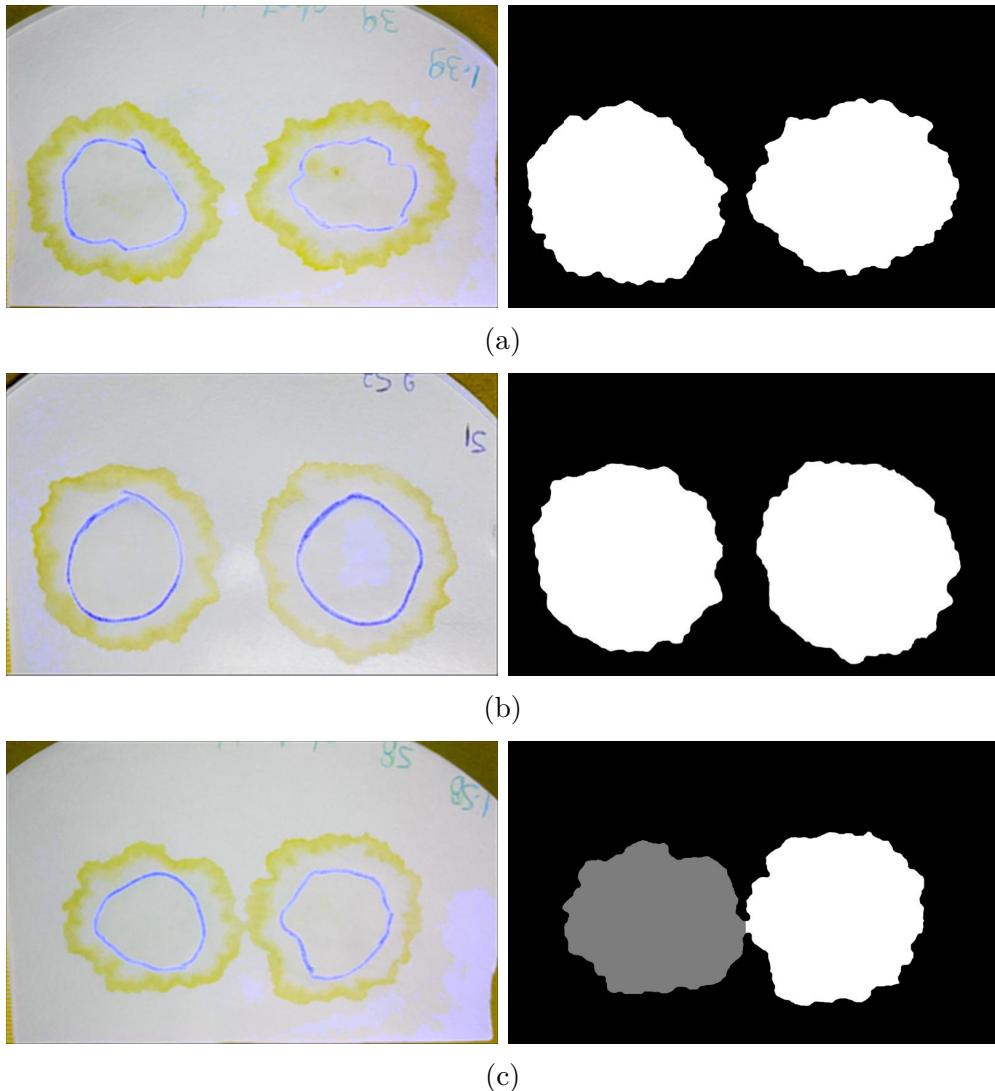


Figura 48 – Resultados da etapa de segmentação da área externa ocorridos com êxito, onde à esquerda se encontram as imagens após o realce do amarelo e à direita o resultado da segmentação. Em (a) e (b) são apresentados os resultados de imagens com diferentes tons de iluminação e intensidades de amarelo. Já em (c) é apresentado um caso no qual foi necessário aplicar o *K-means*, onde um terceiro tom foi aplicado para diferenciar visualmente as amostras.

Conforme mencionado, para uma minoria dos casos, nem todas as amostras puderam ser segmentadas por completo. Isso se deve a grande semelhança entre a coloração da borda da amostra e o filtro de papel, onde nem mesmo com a aplicação da técnica de

realce do amarelo foi possível identificá-las. Apenas uma pequena parte da amostra não é identificada, como mostrado na Figura49.

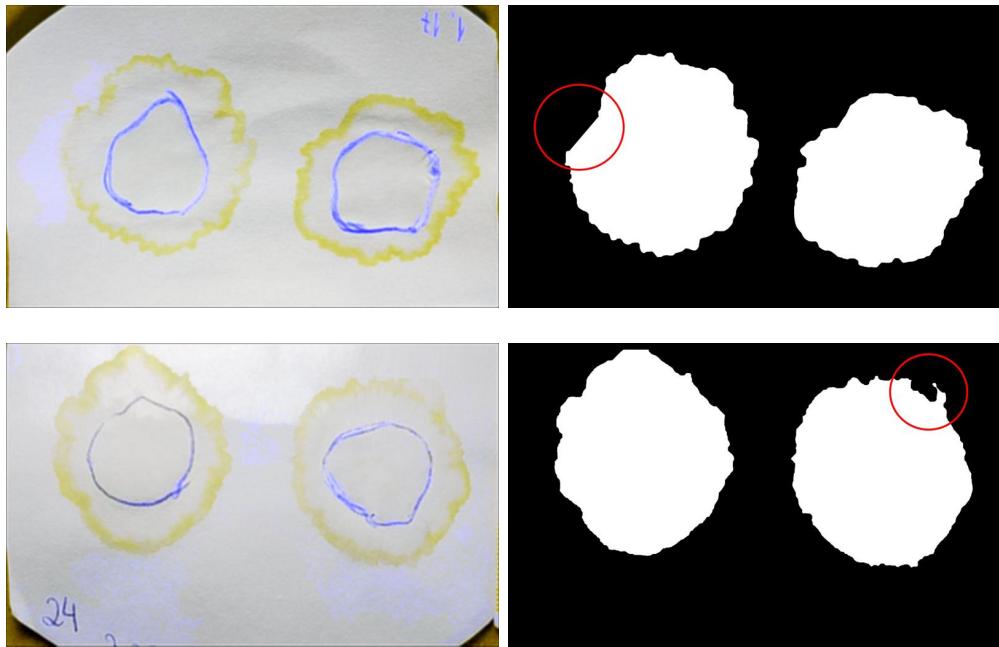


Figura 49 – Resultados da etapa de segmentação da área externa que não puderam ser completamente segmentados, onde à esquerda se encontram as imagem após o realce do amarelo e à direita o resultado da segmentação com os erros destacados em vermelho.

Levando em consideração todo o conjunto de imagens, em alguns casos raros há a possibilidade de apenas uma das amostras ser identificada por completo e somente uma pequena parte da segunda ser reconhecida. Nesses casos, como o tamanho de uma das amostras é maior do que 10 vezes o segundo maior elemento, é entendido que as bordas das duas amostras estão interligadas, o que não é verdade. Sendo assim, o algoritmo *K-means* é aplicado, equivocadamente, na tentativa de reconhecer as duas amostras, como mostrado na Figura50.

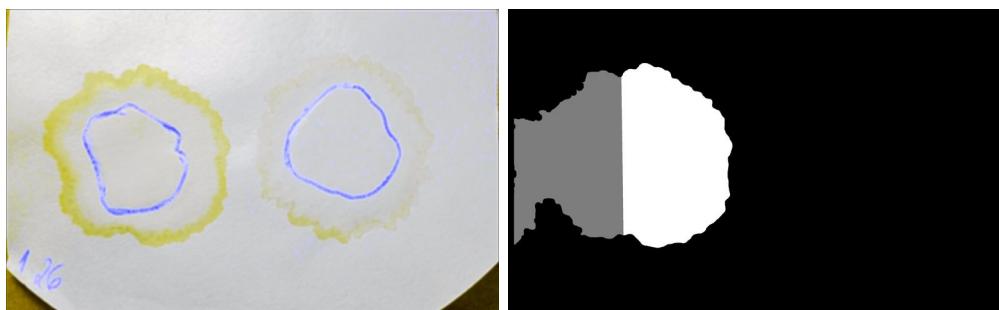


Figura 50 – Resultado da etapa de segmentação da área externa onde as duas amostras não foram segmentadas de forma correta, onde à esquerda se encontra a imagem após o realce do amarelo e à direita o resultado da segmentação.

Assim como na etapa anterior, a segmentação da área interna também obteve bons resultados. De modo geral, o método proposto conseguiu identificar as áreas internas demarcadas por canetas de diferentes cores, até mesmo em certos casos onde as amostras possuíam algum tipo de falha nas suas marcações. Isso pode ser explicado devido a realização de uma boa limiarização e também a aplicação de técnicas como a detecção de pontos extremos. Na Figura 51 é possível observar alguns experimentos da segmentação da área interna que obtiveram êxito.

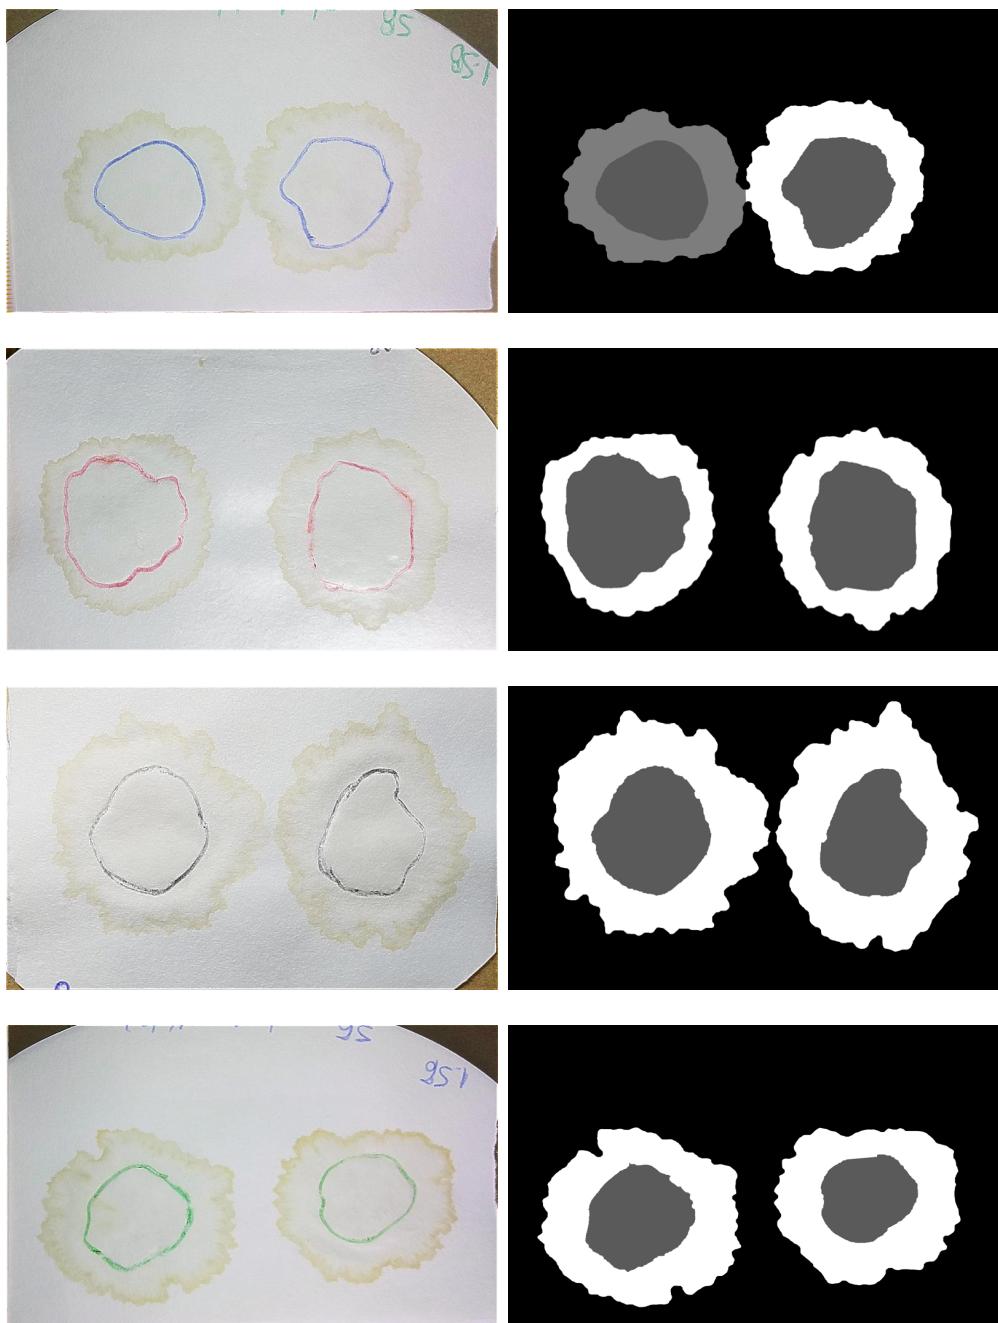


Figura 51 – Resultados da etapa de segmentação da área interna ocorridos com êxito, onde à esquerda estão as imagens originais e à direita os resultados da segmentação.

No entanto, como essa etapa é aplicada apenas na região da amostra segmentada pelo

passo anterior, o sucesso desta etapa depende diretamente do resultado da segmentação da área externa. Isto é, se a área externa de uma amostra não for bem segmentada, é bem provável que a segmentação da área interna também seja afetada, pois essa etapa utiliza a área externa segmentada como máscara para a sua segmentação.

Em algumas exceções o método proposto não conseguiu identificar as marcações por completo devido a presença de grandes falhas em suas áreas demarcadas, como marcações incompletas ou regiões com pouca tinta. Nesses casos, pode ser que apenas pequenos pontos sejam identificados e nem mesmo com a técnica de detecção de pontos extremos seja possível segmenta-las por completo. Na Figura 52 são demonstrados alguns experimentos de outras imagens do dataset que não tiveram bons resultados.

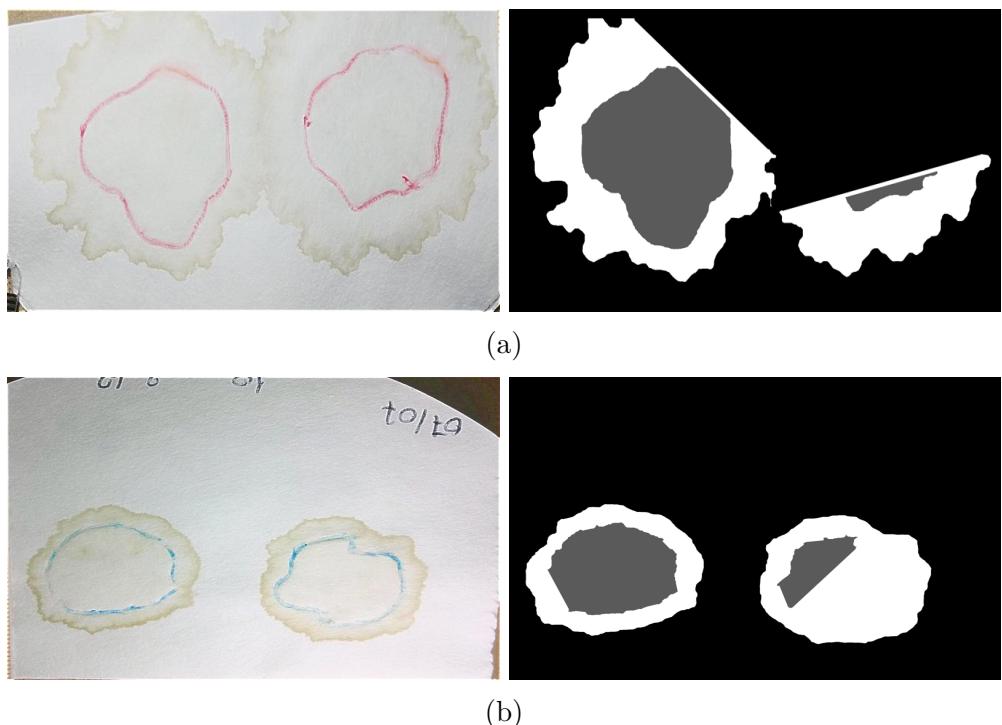


Figura 52 – Resultados da etapa de segmentação da área interna que não puderam ser corretamente segmentados, onde (a) representa o resultado de uma segmentação da área interna influenciada pela externa e (b) a segmentação de uma amostra com falhas nas suas marcações.

4.3 Avaliação dos Resultados

A efetividade do método proposto foi avaliada a partir da realização de dois estudos. No primeiro são avaliadas as quantidades de amostras que foram corretamente segmentadas. No segundo estudo as CRAs de algumas amostras obtidas pelo método proposto são comparadas com as de um especialista.

4.3.1 Análise da Segmentação

O primeiro passo para avaliar a eficiência da segmentação do método proposto foi comparar os resultados de sua aplicação em todas as 665 imagens do dataset. Nesse estudo, os resultados da segmentação são comparados com as suas respectivas imagens originais e as suas regiões segmentadas são verificadas visualmente por um especialista. O sucesso da segmentação de uma amostra é determinado pela semelhança visual entre a área segmentada e a original.

Na Tabela 1 é possível observar os resultados da segmentação obtidos pelo método proposto. Nela são apresentados o número de amostras analisadas, as quantidades de regiões que foram ou não corretamente segmentadas e também a porcentagem de acertos.

Tabela 1 – Informações obtidas via análise visual sobre o aproveitamento das segmentações das regiões externas e internas das 1330 amostras (duas por imagem) do dataset. Na terceira linha são apresentadas as informações do aproveitamento da segmentação da área interna e externa de uma mesma amostra.

Regiões	Total Amostras	Regiões Segmentadas Corretamente	Regiões Segmentadas Incorretamente	Porcentagem Acertos
externa	1330	1274	56	95.7%
interna	1330	1275	55	95.8%
externa e interna	1330	1241	89	93.3%

Com base nessas informações, é possível perceber que a quantidade de regiões que puderam ser segmentadas corretamente foi elevada, já que todas obtiveram pelo menos 93% de aproveitamento. Dentre esses resultados estão inclusos casos onde as duas regiões de uma mesma amostra foram segmentadas corretamente. Isso permitiu que um grande número de amostras pudessem ter as suas CRAs calculadas.

Por ser uma avaliação visual, os dados apresentados na Tabela 1 podem não ser exatos. Em alguns casos é possível que pequenas divergências entre o tamanho das regiões segmentadas e as suas originais passem despercebidas aos olhos. Sendo assim, somente este estudo não é capaz de comprovar a eficiência do método proposto. Entretanto, a sua eficiência poderá se comprovada juntamente com os resultados do próximo estudo, onde a sua precisão é avaliada a partir da análise de CRA.

4.3.2 Análise da CRA

Para avaliar a precisão do método proposto informações como tamanho das regiões internas e externas das amostras são extraídas e suas CRAs são comparadas com os dados de uma segmentação manual realizada por um especialista. Com o auxílio do software

ImageJ[®], os profissionais conseguem extrair a quantidade de pixels de cada região da amostra e com isso calcular a sua CRA.

Devido a alguns fatores como o tempo que se leva para realizar uma segmentação manual e a indisponibilidade dos profissionais especialistas, apenas os dados de 8 das 16 imagens selecionadas foram comparados. Na Tabela 2 é possível observar os dados obtidos após a aplicação do método proposto em algumas imagens do subconjunto e na Tabela 3 são apresentados os dados dessas mesmas imagens extraídos manualmente por um profissional especialista.

Tabela 2 – Informações das amostras obtidas a partir da aplicação do método proposto no grupo de imagens selecionadas, onde *A* corresponde a amostra do lado esquerdo e *B* a do lado direito da imagem.

Imagen	CRA A	CRA B	CRA Média
1	0,382	0,462	0,422
2	0,473	0,420	0,446
3	0,403	0,453	0,428
4	0,481	0,430	0,455
5	0,365	0,405	0,385
6	0,480	0,406	0,443
7	0,509	0,442	0,475
8	0,314	0,285	0,300

Tabela 3 – Informações das amostras do grupo de imagens selecionadas obtidas manualmente por um profissional especialista, onde *A* corresponde a amostra do lado esquerdo e *B* a do lado direito da imagem.

Imagen	CRA A	CRA B	CRA Média
1	0,285	0,353	0,319
2	0,449	0,413	0,431
3	0,389	0,438	0,414
4	0,458	0,419	0,439
5	0,349	0,389	0,369
6	0,441	0,382	0,412
7	0,460	0,399	0,430
8	0,295	0,268	0,281

Na Figura 5 são apresentados gráficos onde são comparadas as CRAs das 8 imagens segmentadas pelo método proposto com as informações das segmentações manuais dessas mesmas imagens cedidas pelo especialista.

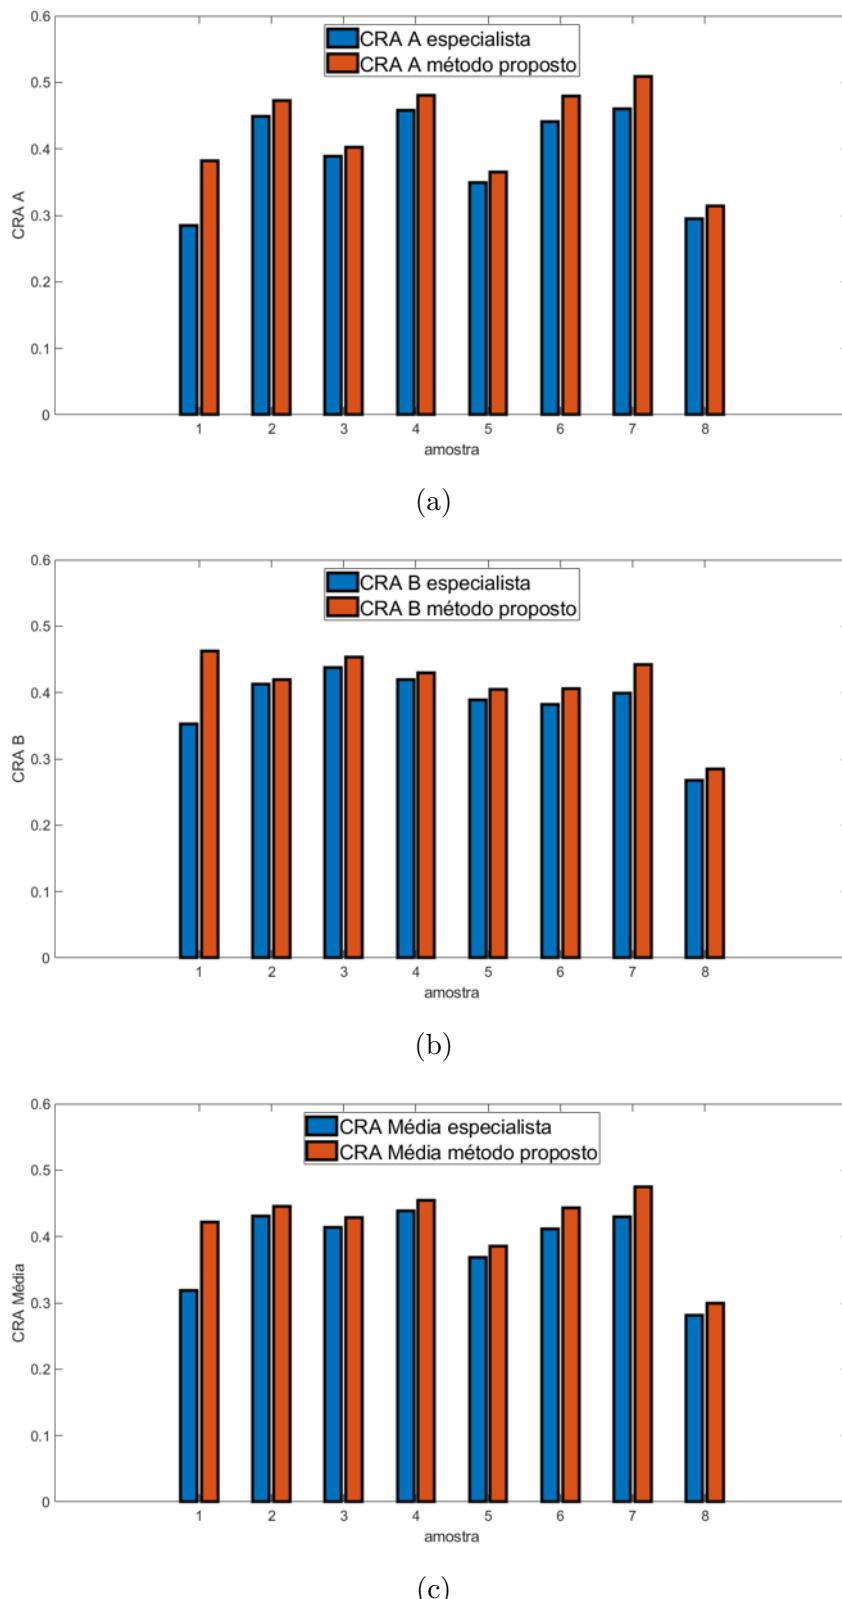


Figura 53 – Comparação entre os resultados obtidos pelo método proposto e pelo especialista, onde em (a) são analisadas apenas as CRAs das amostras localizadas na parte esquerda de cada imagem, em (b) são analisadas as CRAs das segundas amostras localizadas na parte direita e (c) corresponde à média entre as CRAs das duas amostras de cada imagem.

A partir dos resultados obtidos com a análise de CRA, notamos que provavelmente existe uma correlação entre os dados. Em todas as amostras os valores das CRAs extraídas pelo método proposto foi um pouco mais alto do que os valores obtidos pelo especialista, com exceção da primeira amostra onde a diferença foi maior. Na Figura 54 é apresentada a regressão linear da relação entre as médias de CRAs obtidas pelo método proposto e pelo especialista, sem os dados da primeira amostra.

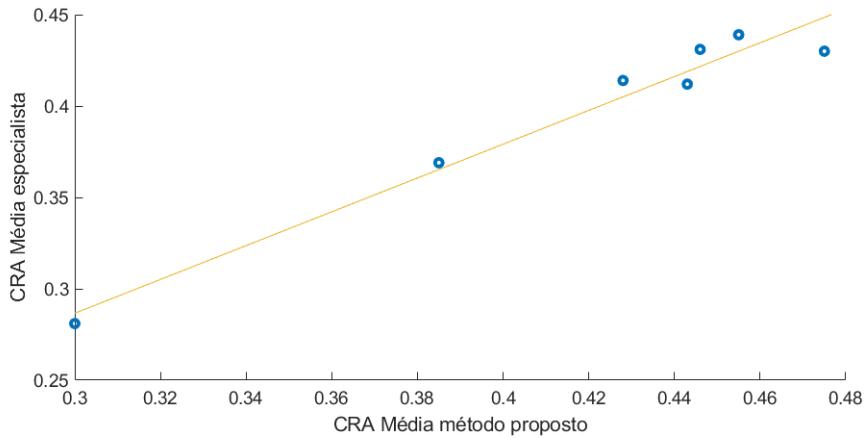


Figura 54 – Regressão linear da relação entre as médias de CRAs obtidas pelo método proposto e pelo especialista.

De acordo com a Figura 54, existe uma correlação entre os dados e essa correlação pode ser calculada a partir da Equação 33. Sendo assim, com o valor de uma CRA extraída pelo método proposto é possível tentar predizer o valor de uma CRA obtida por um especialista. Dessa forma, dados extraídos pelo método proposto poderão ficar ainda mais próximos de segmentações manuais.

$$\hat{y} = \alpha + \beta * x \quad (33)$$

onde \hat{y} corresponde a varável dependente de x , α o ponto onde a reta intercepta o eixo y e β o coeficiente angular (YAMAUTI, 2013).

$$\beta = \frac{n * \sum x_i * y_i - (\sum x_i) * (\sum y_i)}{n * (\sum x_i^2) - (\sum x_i)^2} \quad (34)$$

sendo n o número de linhas do conjunto de dados.

$$\alpha = \frac{\sum y_i}{n} - \beta * \frac{\sum x_i}{n} \quad (35)$$

Conforme demonstrado nos gráficos, os resultados do método proposto foram bastante relevantes. Com exceções da primeira e da sétima amostra, as médias das CRAs do método proposto e do especialista ficaram muito próximas. Como a exatidão nesses casos é praticamente impossível, alguns fatores como possíveis imprecisões tanto do método

proposto quanto do especialista podem justificar essas pequenas divergências entre os resultados. Além disso, a segmentação pelo especialista é realizada de forma inteiramente manual, onde os resultados das marcações podem variar de especialista para especialista. Desse modo, as chances de ocorrer algum erro durante a segmentação manual das regiões das amostras são muito grandes e com isso as medições podem ficar incorretas. Portanto, com base nos resultados apresentados no primeiro e neste estudo, o método proposto pode ser considerado eficaz.

CAPÍTULO 5

Conclusão

O objetivo deste trabalho foi desenvolver um método de segmentação capaz de quantificar as CRAs de amostras de carnes suínas obtidas via método de compressão. Para isso, foi necessário o desenvolvimento de diferentes técnicas de processamento digital de imagens nas quais foram aplicadas e testadas em um dataset composto por imagens de amostras coletadas sob diferentes fatores que influenciam o aspecto final da imagem.

Uma vez definido o método, os experimentos realizados permitiram avaliar a sua eficiência. No primeiro deles foi avaliada a sua capacidade de segmentação, onde todas as imagens do dataset foram segmentadas. No segundo experimento foi avaliada a sua precisão a partir da comparação entre as CRAs obtidas pelo método proposto com as de um especialista. Ambos os experimentos obtiveram resultados satisfatórios, sendo que um elevado número de imagens puderam ser segmentadas corretamente e na maioria dos casos as CRAs obtidas pelo método proposto ficaram muito próximas das CRAs extraídas manualmente pelo especialista.

Uma grande dificuldade encontrada durante a realização deste trabalho foi reunir os dados referentes às CRAs extraídas manualmente, apenas os dados de uma pequena parte do conjunto puderam ser comparados. Isso pode ser justificado pelo tempo gasto para realizar uma segmentação manual e também pela indisponibilidade dos profissionais especialistas. Porém, a eficiência do método proposto pôde ser reforçada pelos excelentes resultados obtidos no primeiro experimento, onde todas as imagens do dataset foram segmentadas de acordo com o esperado.

Algumas pequenas limitações do método proposto foram identificadas durante a re-realização deste trabalho. A primeira delas é que por falta de padronização do processo de digitalização das amostras, muitas delas são fotografadas sobre diferentes superfícies. Dependendo do local de onde elas são colocadas, a coloração do fundo da imagem e até mesmo a presença de outros objetos podem prejudicar o resultado da etapa de recorte do fundo e consequentemente a segmentação. Outra preocupação é a semelhança de coloração entre as amostras e o papel no qual elas são colocadas. Em alguns casos nem mesmo com a aplicação de técnicas de realce e outros métodos foi possível identificá-las por com-

pleto. Apesar dessas limitações, de modo geral o método proposto se mostrou bastante eficiente, alcançando resultados satisfatórios em todos os experimentos realizados durante este trabalho.

5.1 Principais Contribuições

A partir dos resultados apresentados neste trabalho é possível afirmar que o método proposto foi capaz de cumprir o seu objetivo de forma satisfatória. Sendo assim, esta pesquisa poderá auxiliar os profissionais da área de controle de qualidade de alimentos a realizar uma quantificação de CRA mais precisa, automática, prática e com menor custo. Além disso, este trabalho também pode auxiliar futuros pesquisadores a aperfeiçoar e criar novas técnicas de segmentação relacionadas à qualidade da carne suína ou até mesmo em outras áreas.

Como contribuições bibliográficas, a partir deste trabalho foram criados os artigos *Non-Uniform Illumination Correction Applied to Water Retention Capacity Images*, submetido no XV Workshop de Visão Computacional e o artigo *Automated Assessment of Water Holding Capacity in Digital Images*, submetido à revista científica *Food Control*.

5.2 Trabalhos Futuros

Com o objetivo de comprovar ainda mais a eficiência do método proposto, pretende-se realizar um novo experimento onde um número maior de amostras segmentadas pelo especialista serão comparadas com os resultados do método proposto. Também é sugerido a realização de um trabalho que compare os resultados obtidos pelo método proposto com uma segmentação automática que utilize algum algoritmo de aprendizado de máquina, como redes neurais convolucionais para identificação das regiões de interesse da imagem. Outra sugestão interessante é a realização de um trabalho que desenvolva um aplicativo contendo o método proposto para que o profissional responsável pela análise de CRA possa fotografar e quantificar as CRAs das amostras diretamente no local onde ele estiver.

Referências

ABDULLAH, B. M. et al. Assessing water-holding capacity (whc) of meat using microwave spectroscopy. In: MASON, A. (Ed.). **Sensing Technology: Current Status and Future Trends I**. [S.l.]: Springer International Publishing, 2014. p. 117–140. ISBN 9783319023182.

ABREU, A. F. de. **Estudo e Desenvolvimento de Algoritmos de Esqueletização com Aplicação em Redes Vasculares Ósseas**. Dissertação (Mestrado) — Faculdade de Computação, Universidade Federal de Uberlândia, Uberlândia, MG, Brasil, 2016.

ALVES, L. R. **Qualidade de carne Suína. 1. Efeito do Gene Halotano sobre a decomposição de Gordura Intramuscular. 2 Efeito da Suplementação com Minerais Pré-Abate**. Dissertação (Mestrado) — Faculdade de Medicina Veterinária, Universidade Federal de Uberlândia, Uberlândia, MG, Brasil, 2011.

ANDREZZA, I. L. P. **Análise de Técnicas de Normalização Aplicadas ao Reconhecimento Facial**. Dissertação (Mestrado) — Centro de Informática, Universidade Federal da Paraíba, João Pessoa, PB, Brasil, 2015.

DENGA, Y. et al. Fuzzy dijkstra algorithm for shortest path problem under uncertain environment. **Applied Soft Computing**, v. 12, p. 1231–1237, março 2015. Disponível em:<<https://doi.org/10.1016/j.asoc.2011.11.011>>.

DUARTE, M. de A. **Comparação entre as Técnicas de Morfologia Matemática e Contornos Ativos Geodésicos na Segmentação de Microcalcificações em Mamografias**. Tese (Doutorado) — COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil, 2015.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2. ed. New York, NY, USA: wiley interscience, 2001. ISBN 9780471056690.

ELMASRY, G.; SUN, D.-W.; ALLEN, P. Non-destructive determination of water-holding capacity in fresh beef by using nir hyperspectral imaging. **Food Research International**, v. 44, p. 2624–2633, novembro 2011. Disponível em:<<https://doi.org/10.1016/j.foodres.2011.05.001>>.

FAO. **Food Outlook Biannual Report on Global Food Markets**. Roma: FAO, 2018. Disponível em:<<http://www.fao.org/3/ca2320en/CA2320EN.pdf>>.

FEITOSA, R. D. F. **Modelos Matemáticos para a Redução do Espectro Provável e Detecção de Tons de Pele Humana em Imagens Coloridas Representadas nos Espaços de Cores RGB e HSV.** Dissertação (Mestrado) — Instituto de Informática, Universidade Federal de Goiás, Goiânia, GO, Brasil, 2015.

FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens.** Rio de Janeiro, RJ, Brasil: Brasport, 1999. ISBN 8574520098.

FILHO, R. de A. T. et al. Drip loss assessment by different analytical methods and their relationships with pork quality classification. **Journal of Food Quality**, v. 2017, p. 8, agosto 2017. Disponível em:<<https://doi.org/10.1155/2017/9170768>>.

FREITAS, J. da S. **Implementação de uma Arquitetura para Binarização de Imagens em FPGA.** Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, Brasil, 2012.

GONDIM, P. H. C. C. **Desenvolvimento de um Método para Segmentação de Imagens Histológicas da Rede Vascular Óssea.** Dissertação (Mestrado) — Faculdade de Computação, Universidade Federal de Uberlândia, Uberlândia, MG, Brasil, 2018.

GONZALEZ, R.; WOODS, R. **Digital Image Processing.** 3. ed. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2008. ISBN 9788576054016.

GRAU, R. H.; HAMM, R. A. Eine einfache methode zur bestimmung der wasserbindung im muskel. **Naturwissenschaften**, v. 40, p. 29–30, janeiro 1953. Disponível em: <<https://doi.org/10.1007/BF00595734>>.

GRAZIOSI, D. B. **Contribuições à Compressão de Imagens com e sem Perdas Utilizando Recorrência de Padrões Multiescalas.** Tese (Doutorado) — OPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil, 2011.

GUNENC, A. **Evaluation of Pork Meat Quality by Using Water Holding Capacity and Vis-Spectroscopy.** Dissertação (Mestrado) — Department of Bioresource Engineering Macdonald Campus, McGill University, Montreal, QC, Canada, 2007.

JESUS, A. M. de. **Uma Abordagem para Extração de Texto em Vídeos Digitais Baseada em Análise Temporal.** Dissertação (Mestrado) — Pontifícia Universidade Católica de Minas Gerais, Belo Horizonte, MG, Brasil, 2011.

JOO, S.-T. Determination of water-holding capacity of porcine musculature based on released water method using optimal load. **Food Science of Animal Resources**, v. 38, p. 823–828, agosto 2018. Disponível em:<<https://doi.org/10.5851/kosfa.2018.e18>>.

JUNIOR, J. J. M. S. et al. Plant species identification using shortest paths in 2 graphs applied to color images of palisade parenchyma. **Ecological Informatics**, v. 39, Abril 2017. Disponível em:<<https://doi.org/10.1016/j.ecoinf.2017.04.006>>.

KAEWTHONG, P.; WAIYAGAN, K.; WATTANACHANT, S. Imaging analysis by digital camera for separating broiler breast meat with low water-holding capacity. **The Journal of Poultry Science**, v. 54, p. 253–261, março 2017. Disponível em: <<https://doi.org/10.2141/jpsa.0160122>>.

- KATOH, K. An improved method for determining water holding capacity of meat. **Nihon Chikusan Gakkaiho**, v. 52, p. 139–141, fevereiro 1981. Disponível em: <<https://doi.org/10.2508/chikusan.52.139>>.
- LINDEN, R. Técnicas de agrupamento. **Revista de Sistemas de Informação da FSMA**, v. 4, p. 18–36, 2009. Disponível em:<http://www.fsma.edu.br/si/edicao4/FSMA_SI_2009_2_Tutorial.pdf>.
- MALHEIROS, L. **Detecção de Posição e Quedas Corporais Baseado em K-means Clustering e Threshold**. Dissertação (Mestrado) — Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF, Brasil, 2017.
- MARIN, E. S. **Fluzz Redes Sociais: Geração, Visualização e Buscas que Maximizam a Probabilidade de Influência entre Indivíduos**. Dissertação (Mestrado) — Instituto de Informática, Universidade Federal de Goiás, Goiânia, GO, Brasil, 2013.
- MARINS, F. A. S. **Introdução à Pesquisa Computacional**. Guaratinguetá, SP, Brasil: Cultura Acadêmica, 2011. ISBN 9788579831676.
- NEGRI, M. A. S. **Caminhos em um Grafo e o Algoritmo DE Dijkstra**. Dissertação (Mestrado) — Centro de Ciências Físicas e Matemáticas, Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil, 2017.
- NEVES, P. T. **Variações e Aplicações do Algoritmo de Dijkstra**. Dissertação (Mestrado) — Instituto de Computação, Universidade Estadual de Campinas, Campinas, SP, Brasil, 2007.
- PLOTZE, O. M. B. R. O. Estudo e comparação de algoritmos de esqueletonização para imagens binárias. **IV Congresso Brasileiro de Computação – CBCComp 2004**, p. 59–64, 2004.
- PRATT, W. K. **Digital Image Processing**. 4. ed. Hoboken, NJ, USA: John Wiley and Sons, 2007. ISBN 9780471767770.
- RIBEIRO, J. M. **Segmentação de Pele Humana em Imagens Coloridas Baseada em Valores das Médias da Vizinhança em Subimagens**. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, Brasil, 2007.
- RUBERTO, C. D. Recognition of shape by attributed skeletal graphs. **Pattern Recognition**, v. 37, p. 21–31, janeiro 2004. Disponível em:<<https://doi.org/10.1016/j.patcog.2003.07.004>>.
- RUSS, J. C. **The Image Processing Handbook**. New York, NY, USA: John Wiley and Sons, 2007. ISBN 0849372542.
- SANTOS, P. V. dos. **Metodologia para Análise de Imagens de Baixa Resolução, para Definição de MUB (Mapa Urbano Básico) para Apoio às Concessionárias de Distribuição**. Dissertação (Mestrado) — Instituto de Informática, Universidade Federal de Goiás, Goiânia, GO, Brasil, 2018.
- SONKA, M.; HLAVAC, V.; BOYLE, R. **Image Processing, Analysis, and Machine Vision**. 3. ed. Toronto, ON, Canada: Thompson Learning, 2008. ISBN 9780495082521.

SOUZA, G. B. de C. **Otimização do Posicionamento de Concentradores GPRS em Redes Elétricas Inteligentes Utilizando Programação Linear e Teoria de Filas.** Dissertação (Mestrado) — Escola de Engenharia Elétrica, Mecânica e de Computação, Universidade Federal de Goiás, Goiânia, GO, Brasil, 2014.

UCHOA, J. S. **Caminhos Mínimos com Recursos Limitados.** Dissertação (Mestrado) — Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, SP, Brasil, 2007.

WAGSTAF, K. et al. Constrained k-means clustering with background knowledge. **Proceedings of the Eighteenth International Conference on Machine Learning - ICML 2001**, p. 577–584, 2001.

YAMAUTI, M. M. **Regressão Linear Simples nos livros de Estatística para cursos de Administração: um estudo didático.** Dissertação (Mestrado) — Pontifícia Universidade Católica de São Paulo, São Paulo, SP, Brasil, 2013.

ZAGHETTO, A. **Compressão de Documentos Compostos Utilizando o H.264/AVC-INTRÁ.** Tese (Doutorado) — Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF, Brasil, 2009.