

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**MÉTODO PARA CLASSIFICAÇÃO DE
SEMENTES AGRÍCOLAS EM IMAGENS
OBTIDAS POR TOMOGRAFIA DE RAIOS-X EM
ALTA RESOLUÇÃO**

ANDRÉ RIBEIRO DE BRITO

ORIENTADOR: PROF. DR. PAULO ESTEVÃO CRUVINEL

São Carlos – SP

Maio, 2020

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**MÉTODO PARA CLASSIFICAÇÃO DE
SEMENTES AGRÍCOLAS EM IMAGENS
OBTIDAS POR TOMOGRAFIA DE RAIOS-X EM
ALTA RESOLUÇÃO**

ANDRÉ RIBEIRO DE BRITO

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação, área de concentração: Processamento de Imagens e Sinais.

Orientador: Prof. Dr. Paulo Estevão Cruvinel

São Carlos – SP

Maio, 2020



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

Folha de Aprovação

Assinaturas dos membros da comissão examinadora que avaliou e aprovou a Defesa de Dissertação de Mestrado do candidato André Ribeiro de Brito, realizada em 20/05/2020:

Prof. Dr. Paulo Estevão Cruvinel
EMBRAPA

Prof. Dr. Cesar Henrique Comin
UFSCar

Prof. Dr. Marcelo Andrade da Costa Vieira
EESC/USP

Certifico que a defesa realizou-se com a participação à distância do(s) membro(s) Cesar Henrique Comin, Marcelo Andrade da Costa Vieira e, depois das arguições e deliberações realizadas, o(s) participante(s) à distância está(ao) de acordo com o conteúdo do parecer da banca examinadora redigido neste relatório de defesa.

Prof. Dr. Paulo Estevão Cruvinel

Este trabalho é dedicado aos meus pais, Raimundo e Isabel, aos meus irmãos, Rafael, Ewerton e Anderson.

AGRADECIMENTOS

Agradeço em primeiro lugar à Deus por está sempre presente nessa minha jornada, seja apoiando em momentos difíceis e momentos de descontração, dando força à cada dia para que conseguisse concluir este trabalho.

Ao meus pais, Raimundo C. de Brito e Isabel R. da Cruz, pelo amor, apoio e iniciativa nessa minha caminhada.

Ao Professor Dr. Paulo Estevão Cruvinel, pela proposta de tema, orientação, paciência, sabedoria e ensinamento à pesquisa desenvolvida.

Aos Professores do Programa de Pós-Graduação em Ciência da Computação da UFSCar, com os quais tive a oportunidade de aprender e adquirir conhecimento.

Aos Professores Dr. Alexandre Luís Magalhães Levada e Dr. Gabriel Marcelino Alves, pelas discussões relativas ao uso PCA e segmentação por grafo, assim como ao Dr. Paulo Renato Orlandi Lasso pelo apoio nos ensaios laboratórias.

Aos meus colegas da Pós-Graduação com os quais pude compartilhar momentos de vitórias e dificuldades.

Ao Programa de Pós-Graduação da Universidade Federal de São Carlos e à Embrapa Instrumentação pelo apoio e suporte no desenvolvimento deste trabalho.

Aos meus irmãos da República MataBurro de Ouro Preto-MG, por sempre compartilharem momentos de alegria e descontração.

À CAPES e ao CNPq (Processo 132077/2018-3) pelo auxílio e apoio durante todo o curso.

Enfim, a todos que auxiliaram indiretamente no desenvolvimento deste trabalho.

RESUMO

Este trabalho apresenta um método para a classificação de sementes agrícolas oleaginosas a partir de ensaios tomográficos de alta resolução. As sementes oleaginosas podem apresentar boa ou má qualidade para o plantio, sendo essa última relacionada à presença de defeitos associados às imperfeições físicas como trincas, quebras e vazios. Para o desenvolvimento do método foram consideradas as reconstruções de fatias tomográficas em alta resolução, como também a avaliação de técnicas do processamento e visualização de imagens digitais, ou seja, avaliações relacionadas ao pré-processamento, segmentação, extração de características e classificadores supervisionados. Para a sua avaliação, foram consideradas amostras contendo sementes agrícolas oleaginosas com e sem defeitos para girassol (*Helianthus annuus* L.), de pinhão-manso (*Jatropha curcas* L.) e de soja (*Glycine max* (L.) Merrill). Para a escolha das técnicas de pré-processamento, processamento e visualização de imagens tomográficas foram utilizadas as métricas PSNR (*Peak Signal-to-Noise Ratio*), MSE (*Mean Square Error*), SSIM (*Structural Similarity Index Measure*) e DSC (*Dice Similarity Coefficient*). Desta forma, para o estabelecimento do método, as técnicas selecionadas para filtragem e segmentação foram as baseadas em filtro Non-local means e o Gaussiano, enquanto para as etapas de segmentação, foram baseadas técnicas de limiarização simples e grafo, respectivamente. Para etapa de extração de características, foram selecionadas as técnicas de HOG (*Histogram of Oriented Gradients*) e momentos invariantes de Hu, por permitirem a obtenção de descritores de textura e de descritores baseados em características geométricas, respectivamente. Adicionalmente, foi utilizada a técnica de PCA (*Principal Component Analysis*) para o estabelecimento de um vetor de características composto com esses descritores mencionados. Finalmente, foram avaliados e considerados os classificadores NB (Naïve Bayes) e SVM (*Support Vector Machine*). Para o método o classificador NB foi indicado para a análise das fatias tomográficas das sementes de girassol e o classificador SVM para a análise das fatias tomográficas das sementes de pinhão-manso e de soja. O método desenvolvido para a classificação de sementes oleaginosas se mostrou adequado para a seleção no pré-plantio, o que contribui para o auxílio à tomada de decisão na seleção de sementes agrícolas de boa qualidade. Também, contribui para a evolução de técnicas avançadas e ferramentas de análises, obtidas a partir de técnicas do processamento e visualização de imagens digitais.

Palavras-chave: Processamento Digital de Imagens, Tomografia de Raios-X, Classificadores Supervisionados, Classificação de Sementes Agrícolas.

ABSTRACT

This research produced a method for classifying agricultural oil seeds based on tomography (CT) assays. Oilseeds may present good or poor quality for planting, the latter being related to the presence of defects associated with physical imperfections such as cracks, breaks and voids. In such a context, for the development of the method, high-resolution tomographic slices reconstruction have been considered, as well as the evaluation of digital image processing and visualization techniques, i.e., evaluations related to pre-processing, segmentation, extraction of supervised characteristics and classifiers. For such evaluations, samples containing oilseeds with and without defects for sunflower (*Helianthus annuus* L.), physic nut (*Jatropha curcas* L.), and soybean (*Glycine max* (L.) Merrill) were classified. For the choice of the pre-processing, processing and visualization of tomographic images techniques, the following metrics were used: PSNR (Peak Signal-to-Noise Ratio), MSE (Mean Square Error), SSIM (Structural Similarity Index Measure), and DSC (Dice Similarity Coefficient). Thus, for the establishment of the method, the techniques for filtering and segmentation have been selected considering the Non-local means and Gaussian filters, while for the segmentation steps, the simple thresholding and graph techniques have been selected, respectively. For the characteristic extraction stage, the HOG (Histogram of Oriented Gradients) and the Hu invariant moments techniques have been selected, as they can allow obtaining texture descriptors and descriptors based on geometric characteristics, respectively. Additionally, the PCA (Principal Component Analysis) technique has been used to establish a composite characteristic vector with these descriptors. Finally, not only the NB (Naïve Bayes) but also the SVM (Support Vector Machine) classifier shown its usefulness. Furthermore, for the method, the NB classifier has been indicated for the analysis of tomographic slices of sunflower seeds and the SVM classifier for the analysis of tomographic slices of jatropha and soybean seeds. The method developed for the grading of oilseeds has been shown to be suitable for selection in pre-planting, which helps to assist decision making in the selection of good quality agricultural seed. It also contributes to the evolution of advanced techniques and analysis tools, obtained from digital image processing and visualization techniques.

Keywords: Digital Image Processing, X-ray Tomography, Supervised Classifiers, Agricultural Oilseeds.

LISTA DE SIGLAS

AD	Agricultura de Decisão
CCD	Charge-Coupled Device
DSC	Dice Similarity Coefficients
HOG	Histogram of Oriented Gradients
MSE	Mean Squared Error
MI _s	Momentos Invariantes
NLM	Non-Local Means
ONU	Organizações Nações Unidas
PCA	Principal Component Analysis
PSNR	Peak Signal to Noise Ratio
RAM	Random Access Memory
ROI	Region of Interest
SSIM	Structural Similarity Index Measure
SVM	Support Vector Machine
TC	Tomografia Computadorizada

LISTA DE SÍMBOLOS

α	Letra grega Alpha
δ	Letra grega Delta
η	Letra grega Eta
Γ	Letra grega Gama
ι	Letra grega Iota
κ	Letra grega Kappa
Λ	Letra grega Lambda
μ	Letra grega Mi
ν	Letra grega Nu
ϵ	Letra grega Pertence
Ω	Letra grega Omega
π	Letra grega Pi
Φ	Letra grega Phi
ψ	Letra grega Psi
σ	Letra grega Sigma
τ	Letra grega Tau
θ	Letra grega Theta
φ	Letra grega Varphi
ϑ	Letra grega Vartheta
ζ	Letra grega Zeta

LISTA DE FIGURAS

Figura 1 – Representação ilustrativa de uma metodologia para a aquisição de imagens tomográficas (Fonte: Adaptado de Hounsfield (1973)).	40
Figura 2 – Exemplos de imagens tomográficas bidimensional (2a e 2b) e tridimensional (2c) do solo agrícola (Fonte: Retirado de Beraldo et al. (2014) e Pereira e Cruvinel (2015))	41
Figura 3 – Transformada de Radon para uma projeção $f(x,y)$ (Fonte: Adaptado de Rangayyan (2004)).	41
Figura 4 – Representação da intensidade do feixe de raios-X sobre uma pilha de <i>pixels</i> (Fonte: Adaptado de Seeram (2010)).	42
Figura 5 – Teorema do corte de Fourier (Fonte: Adaptado de Rangayyan (2004)).	43
Figura 6 – Diagrama de blocos das etapas do processamento de imagens (Fonte: Adaptado de Gonzalez e Woods (2007))	44
Figura 7 – Representação ilustrativa do conceito de vizinhança do <i>pixel</i> , sendo vizinhança-4 (7a), vizinhança diagonal (7b) e vizinhança-8 (7c) (Fonte: Adaptado de Filho e Neto (1999)).	46
Figura 8 – Diagrama de blocos da etapa de filtragem da imagem (Fonte: Adaptado de Banham e Katsaggelos (1997)).	47
Figura 9 – Diagrama esquemático do processo do filtro de média utilizando uma máscara 3x3 (Fonte: Adaptado de GONZALEZ e WOODS (1992)).	48
Figura 10 – Diagrama esquemático do processo do filtro da mediana utilizando uma matriz de convolução com dimensão 3x3, onde $K = 1$	49
Figura 11 – Estrutura computacional esquemática para o algoritmo do método de Difusão Anisotrópica (Fonte: Adaptado de Perona et al. (1994)).	51
Figura 12 – Diagrama de ganhos versus frequência para os filtros passa-faixa, o passa-alta e o passa-baixa (Fonte: Adaptado de Oppenheim et al. (1998)).	53
Figura 13 – Método para segmentação de imagem usando corte em grafo (Fonte: Adaptado de Boykov e Jolly (2001)).	58
Figura 14 – Representação do funcionamento do descritor HOG (Fonte: Adaptado de Dalal (2006)).	61
Figura 15 – Representação ilustrativa do modelo aplicado para o reconhecimento de padrões (Fonte: Adaptado de Jain et al. (2000)).	63

Figura 16 – Representação ilustrativa do classificador SVM, indicando a margem e os vetores de suporte (Fonte: Adaptado de Schütze et al. (2007)).	65
Figura 17 – Representação da função KERNEL do espaço bidimensional (Figura 17a) e o espaço tridimensional (Figura 17b) (Fonte: Adaptado de Cristianini e Shawe-Taylor (2000)).	66
Figura 18 – Representação ilustrativa de sementes de girassol.	72
Figura 19 – Representação ilustrativa de sementes de pinhão-manso.	72
Figura 20 – Representação ilustrativa de sementes de soja.	73
Figura 21 – Diagrama de blocos dos métodos baseado em visão computacional e reconhecimento de padrões para de sementes agrícolas (Fonte - Elaborado pelo autor).	74
Figura 22 – Foto do tomógrafo de alta resolução modelo SkyScan 1172 (Fonte:Skyscan 1172 user manual).	75
Figura 23 – Exemplo de fatias tomográficas referentes às sementes de girassol (23a), de pinhão-manso (23b) e de soja (23c).	76
Figura 24 – Procedimento realizado para o método de segmentação baseado no uso da técnica em grafos (Fonte: Adaptado de Gross e Yellen (2005)).	80
Figura 25 – Procedimento realizado para o método de segmentação em grafos (Fonte: Elaborado pelo autor).	81
Figura 26 – Exemplo do resultado da aplicação do filtro de difusão anisotrópica aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (26a), à fatia tomográfica após adição de ruído Gaussiano (26b), ao ROI da fatia tomográfica ruidosa (26c) e à fatia tomográfica após a aplicação do filtro (26d).	85
Figura 27 – Exemplo do resultado da aplicação do filtro <i>non-local means</i> aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (27a), à fatia tomográfica após adição de ruído Gaussiano (27b), ao ROI da fatia tomográfica ruidosa (27c) e à fatia tomográfica após a aplicação do filtro (27d).	86
Figura 28 – Exemplo do resultado da aplicação do filtro Gaussiano aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (28a), à fatia tomográfica após adição de ruído Gaussiano (28b), ao ROI da fatia tomográfica ruidosa (28c) e à fatia tomográfica após a aplicação do filtro (28d).	87
Figura 29 – Exemplo do resultado da aplicação do filtro passa-banda ideal aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (29a), à fatia tomográfica após adição de ruído Gaussiano (29b), ao ROI da fatia tomográfica ruidosa (29c) e à fatia tomográfica após a aplicação do filtro (29d).	88
Figura 30 – Resultados obtidos pela métrica MSE ao aplicar em fatias tomográficas de sementes de girassol após a adição do ruído Gaussiano.	89

Figura 31 – Resultados obtidos pela métrica PSNR ao aplicar em fatias tomográficas de sementes de girassol após a adição do ruído Gaussiano.	89
Figura 32 – Resultados obtidos pela métrica SSIM ao aplicar em fatias tomográficas de sementes de girassol após a adição do ruído Gaussiano.	90
Figura 33 – Resultados obtidos pela métrica MSE ao aplicar em fatias tomográficas de sementes de pinhão-mansó após a adição do ruído Gaussiano.	90
Figura 34 – Resultados obtidos pela métrica PSNR ao aplicar em fatias tomográficas de sementes de pinhão-mansó após a adição do ruído Gaussiano.	91
Figura 35 – Resultados obtidos pela métrica SSIM ao aplicar em fatias tomográficas de sementes de pinhão-mansó após a adição do ruído Gaussiano.	91
Figura 36 – Resultados obtidos pela métrica MSE ao aplicar em fatias tomográficas de sementes de soja após a adição do ruído Gaussiano.	92
Figura 37 – Resultados obtidos pela métrica PSNR ao aplicar em fatias tomográficas de sementes de soja após a adição do ruído Gaussiano.	92
Figura 38 – Resultados obtidos pela métrica SSIM ao aplicar em fatias tomográficas de sementes de soja após a adição do ruído Gaussiano.	93
Figura 39 – Exemplo de segmentação pela técnica de limiarização aplicada em fatia tomográfica após o filtro Gaussiano referente à semente de girassol (39a), à fatia tomográfica binarizada da técnica de segmentação (39b) e à conjunção entre as duas fatias tomográficas (39c).	94
Figura 40 – Exemplo de segmentação pela técnica de Otsu aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de girassol (40a), à fatia tomográfica binarizada da técnica de segmentação (40b) e à conjunção entre as duas fatias tomográficas (40c).	94
Figura 41 – Exemplo de processo de equalização do histograma a partir da fatia tomográfica de girassol suavizada com o filtro Gaussiano (41a) e o seu histograma (41b), juntamente com o resultado da fatia tomográfica equalizada (41c) e o seu histograma (41d).	95
Figura 42 – Exemplo de processo feito pela técnica de segmentação em grafo aplicado para a escolha da região pertencente ao vértice virtual objeto e ao vértice virtual fundo referentes à cultura de girassol.	95
Figura 43 – Exemplo de segmentação pela técnica grafo aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de girassol (43a), ao resultado da fatia tomográfica binarizada da segmentação (43b) e à conjunção entre as duas fatias tomográficas (43c).	96
Figura 44 – Resultados obtidos pela métrica DSC em fatias tomográficas de sementes de girassol após a aplicação das técnicas de segmentação por limiarização, Otsu e grafo.	97

Figura 45 – Resultados obtidos pela métrica DSC em fatias tomográficas de sementes de pinhão-mansó após a aplicação das técnicas de segmentação por limiarização, Otsu e grafo.	97
Figura 46 – Resultados obtidos pela métrica DSC em fatias tomográficas de sementes de soja após a aplicação das técnicas de segmentação por limiarização, Otsu e grafo.	98
Figura 47 – Exemplo de extração de característica do método HOG aplicado em fatia tomográfica referente à semente de girassol.	99
Figura 48 – Exemplo de extração de característica do método momentos invariantes de Hu aplicado na fatia tomográfica referente à semente de girassol.	99
Figura 49 – Taxa de variância acumulativa PCA.	100
Figura 50 – Exemplo do resultado da aplicação do filtro de difusão anisotrópica aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-mansó (50a), à fatia tomográfica após adição de ruído Gaussiano (50b), ao ROI fatia da tomográfica ruidosa (50c) e à fatia tomográfica após a aplicação do filtro (50d).	128
Figura 51 – Exemplo do resultado da aplicação do filtro de difusão anisotrópica aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (51a), à fatia tomográfica após adição de ruído Gaussiano (51b), ao ROI fatia da tomográfica ruidosa (51c) e à fatia tomográfica após a aplicação do filtro (51d).	129
Figura 52 – Exemplo do resultado da aplicação do filtro <i>non-local means</i> aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-mansó (52a), à fatia tomográfica após adição de ruído Gaussiano (52b), ao ROI fatia da tomográfica ruidosa (52c) e à fatia tomográfica após a aplicação do filtro (52d).	129
Figura 53 – Exemplo do resultado da aplicação do filtro <i>non-local means</i> aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (53a), à fatia tomográfica após adição de ruído Gaussiano (53b), ao ROI fatia da tomográfica ruidosa (53c) e à fatia tomográfica após a aplicação do filtro (53d).	130
Figura 54 – Exemplo do resultado da aplicação do filtro Gaussiano aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-mansó (54a), à fatia tomográfica após adição de ruído Gaussiano (54b), ao ROI fatia da tomográfica ruidosa (54c) e à fatia tomográfica após a aplicação do filtro (54d).	130
Figura 55 – Exemplo do resultado da aplicação do filtro Gaussiano aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (55a), à fatia tomográfica após adição de ruído Gaussiano (55b), ao ROI fatia da tomográfica ruidosa (55c) e à fatia tomográfica após a aplicação do filtro (55d).	131

Figura 56 – Exemplo do resultado da aplicação do filtro passa-banda ideal aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-manso (56a), à fatia tomográfica após adição de ruído Gaussiano (56b), ao ROI fatia da tomográfica ruidosa (56c) e à fatia tomográfica após a aplicação do filtro (56d).	132
Figura 57 – Exemplo do resultado da aplicação do filtro passa-banda ideal aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (57a), à fatia tomográfica após adição de ruído impulsivo (57b), ao ROI fatia da tomográfica ruidosa (57c) e à fatia tomográfica após a aplicação do filtro (57d).	132
Figura 58 – Exemplo de segmentação pela técnica de limiarização aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de pinhão-manso (58a), à fatia tomográfica binarizada da técnica de segmentação (58b) e à conjunção entre as duas fatias tomográficas (58c).	133
Figura 59 – Exemplo de segmentação pela técnica de limiarização aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de soja (59a), à fatia tomográfica binarizada da técnica de segmentação (59b) e à conjunção entre as duas fatias tomográficas (59c).	133
Figura 60 – Exemplo de segmentação pela técnica de Otsu aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de pinhão-manso (60a), à fatia tomográfica binarizada da técnica de segmentação (60b) e à conjunção entre as duas fatias tomográficas (60c).	134
Figura 61 – Exemplo de segmentação pela técnica de Otsu aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de soja (61a), à fatia tomográfica binarizada da técnica de segmentação (61b) e à conjunção entre as duas fatias tomográficas (61c).	134
Figura 62 – Exemplo de processo de equalização do histograma a partir da fatia tomográfica de pinhão-manso suavizada com o filtro Gaussiano (62a) e o seu histograma (62b), juntamente com o resultado da fatia tomográfica equalizada (62c) e o seu histograma (62d).	135
Figura 63 – Exemplo de processo de equalização do histograma a partir da fatia tomográfica de soja suavizada com o filtro Gaussiano (63a) e o seu histograma (63b), juntamente com o resultado da fatia tomográfica equalizada (63c) e o seu histograma (63d).	135
Figura 64 – Exemplo de segmentação pela técnica grafo, aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de pinhão-manso (64a), ao resultado da fatia tomográfica binarizada da segmentação (64b) e à conjunção entre as duas fatias tomográficas (64c).	136

Figura 65 – Exemplo de segmentação pela técnica grafo aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de Soja (65a), ao resultado da fatia tomográfica binarizada da segmentação (65b) e à conjunção entre as duas fatias tomográficas (65c).	136
Figura 66 – Exemplo de extração de característica do método HOG aplicado na fatia tomográfica referente à semente de pinhão-manso.	137
Figura 67 – Exemplo de extração de característica do método HOG aplicado na fatia tomográfica referente à semente de soja.	137
Figura 68 – Exemplo de extração de característica do método momentos invariantes de Hu aplicado na fatia tomográfica referente à semente de pinhão-manso. . .	137
Figura 69 – Exemplo de extração de característica do método momentos invariantes de Hu aplicado na fatia tomográfica referente à semente de Soja.	138

LISTA DE TABELAS

Tabela 1 – Parâmetros para aquisição das fatias tomográficas.	75
Tabela 2 – Valores aplicados para cada parâmetro do filtro de difusão anisotrópica.	84
Tabela 3 – Valores aplicados para cada parâmetro do filtro <i>non-local means</i>	85
Tabela 4 – Valores aplicados para cada parâmetro do filtro Gaussiano.	86
Tabela 5 – Resultados dos experimentos aplicados para uma base de dados com 80% treinamento e 20% teste usando o classificador Naïve Bayes.	101
Tabela 6 – Resultados dos experimentos aplicados para uma base de dados com 80% treinamento e 20% teste usando o classificador SVM.	101
Tabela 7 – Resultados dos experimentos aplicados para uma base de dados com 70% treinamento e 30% teste usando o classificador Naïve Bayes.	139
Tabela 8 – Resultados dos experimentos aplicados para uma base de dados com 70% treinamento e 30% teste usando o classificador SVM.	139
Tabela 9 – Resultados dos experimentos aplicados para uma base de dados com 60% treinamento e 40% teste usando o classificador Naïve Bayes.	140
Tabela 10 – Resultados dos experimentos aplicados para uma base de dados com 60% treinamento e 40% teste usando o classificador SVM.	140
Tabela 11 – Resultados dos experimentos aplicados para uma base de dados com 50% treinamento e 50% teste usando o classificador Naïve Bayes.	140
Tabela 12 – Resultados dos experimentos aplicados para uma base de dados com 50% treinamento e 50% teste usando o classificador SVM.	141

SUMÁRIO

CAPÍTULO 1–INTRODUÇÃO	20
1.1 Motivação e Contextualização	20
1.2 Objetivos	21
1.2.1 Objetivo Geral	21
1.2.2 Objetivos Específicos	22
1.3 Considerações Finais	22
CAPÍTULO 2–TRABALHOS CORRELATOS	24
2.1 Técnicas da TC de raios-X e Aplicações	24
2.2 Técnicas de aquisição de imagens	25
2.3 Técnicas de pré-processamento de imagens	27
2.4 Principais métricas para análise de imagens	30
2.5 Técnicas de segmentação de imagens	31
2.6 Técnicas de extração de características	34
2.7 Técnicas de reconhecimento e classificação de padrões em imagens	37
2.8 Considerações Finais	38
CAPÍTULO 3–FUNDAMENTAÇÃO TEÓRICA	40
3.1 Tomografia Computadorizada	40
3.1.1 Reconstrução de imagens tomográficas	41
3.1.1.1 Transformada de Radon	43
3.1.1.2 Teorema das Secções de Fourier	43
3.2 Processamento de Imagens	44
3.2.1 Conceito de imagem digital	45
3.2.2 Pré-Processamento	46
3.2.2.1 Ruído em Imagens	46
3.2.2.2 Filtragem	47
3.2.2.2.1 Filtro no Domínio Espacial	47
3.2.2.2.2 Filtros no Domínio da Frequência	52
3.2.3 Segmentação	53
3.2.3.1 Método de Limiarização	54
3.2.3.2 Método de Otsu	54
3.2.3.3 Método de Corte em Grafo	56
3.2.4 Métricas para a Avaliação das Técnicas de Filtragem e Segmentação das Imagens Tomográficas em Alta Resolução de Sementes Oleaginosas	58
3.2.5 Extração de Características	60

3.2.5.1	<i>Histogram of Oriented Gradients (HOG)</i>	60
3.2.5.2	Momentos Invariantes	61
3.2.5.2.1	Momentos Bidimensionais	61
3.2.5.2.2	Momentos Centrais	62
3.2.5.2.3	Momentos Centrais Normalizados	62
3.2.5.2.4	Momentos Invariantes de Hu	62
3.3	Classificadores de Padrões	63
3.3.1	Aprendizado Supervisionado	65
3.3.1.1	Máquina de Vetores de Suporte (<i>Support Vector Machine - SVM</i>)	65
3.3.1.2	Classificador Bayesiano	67
3.3.2	Aprendizado Não Supervisionado	68
3.3.3	Aprendizado Semi-Supervisionado	68
3.4	Análise de Componentes Principais	69
3.5	Considerações Finais	70
CAPÍTULO 4–MATERIAIS E MÉTODOS		71
4.1	Sementes Agrícolas	71
4.1.1	Girassol	71
4.1.2	Pinhão-manso	72
4.1.3	Soja	72
4.2	Modelagem do Sistema	73
4.2.1	Aquisição e organização das fatias tomográficas	75
4.2.2	Qualificação da base de fatias tomográficas	76
4.2.3	Pré-Processamento	77
4.2.4	Segmentação	78
4.2.4.1	Segmentação utilizando a técnica de Limiarização	78
4.2.4.2	Segmentação utilizando a técnica de Otsu	78
4.2.4.3	Segmentação utilizando a técnica de Grafos	78
4.2.5	Extração de Características	81
4.2.6	Estabelecimento do algoritmo para Análise de Componentes Principais	82
4.2.7	Classificação de Padrões	82
4.3	Considerações Finais	83
CAPÍTULO 5–RESULTADOS E DISCUSSÕES		84
5.1	Resultados de Análises das Modalidades de Filtragem das Fatias Tomográficas na Etapa de Pré-Processamento	84
5.2	Análises das Técnicas de Segmentação	93
5.2.1	Resultados da Avaliação das Técnicas de Segmentação Utilizando a Ferramenta Estatística Boxplot Aplicada em Todos os Conjuntos de Fatias Tomográficas	96

5.2.2	Resultados das Avaliações das Técnicas de Extração de Características	98
5.2.3	Resultados Obtidos das Técnicas de Classificação	100
5.2.4	Resultados dos Classificadores	101
5.3	Considerações Finais	102
CAPÍTULO 6–CONCLUSÃO		103
6.1	Atendimento aos Objetivos Específicos e ao Objetivo Geral	103
6.2	Principal Contribuição	104
6.3	Proposta para Trabalhos Futuros	105
REFERÊNCIAS		106
APÊNDICE A–ALGORITMOS		120
A.1	Pré-Processamento	120
A.2	Segmentação	121
A.3	Extração de Características	125
A.4	Análise de Componentes Principais	126
A.5	Classificação	126
APÊNDICE B–RESULTADOS DAS ANÁLISES DAS MODALIDADES DE FILTRAGEM E SEGMENTAÇÃO DAS FATIAS TO- MOGRÁFICAS		128
B.1	Pré-Processamento	128
B.1.1	Resultado do Filtro de Difusão Anisotrópica	128
B.1.2	Resultado do Filtro <i>Non-local Means</i>	129
B.1.3	Resultado do Filtro Gaussiano	130
B.1.4	Resultado do Filtro Passa-banda Ideal	132
B.2	Segmentação	133
B.2.1	Resultado da Segmentação de Limiarização	133
B.2.2	Resultado da Segmentação Otsu	134
B.2.3	Resultado da Segmentação em Grafo	135
B.3	Extração de Características	137
B.3.1	Extração de Características pela Técnica de HOG	137
B.3.2	Extração de Características pela Técnica de Hu	137
APÊNDICE C–RESULTADOS DAS ANÁLISES DOS CLASSIFICADO- RES NAÏVE BAYES E SVM		139
C.1	Experimentos aplicados para uma base de dados com 70% treinamento e 30% teste	139
C.2	Experimentos aplicados para uma base de dados com 60% treinamento e 40% teste	140

C.3 Experimentos aplicados para uma base de dados com 50% treinamento e 50% teste 140

Capítulo 1

INTRODUÇÃO

Neste capítulo, será apresentada a motivação e a contextualização que foram necessárias para o desenvolvimento desse trabalho. Também serão demonstrados os objetivos específicos e o objetivo principal para depois, finalmente, explanar sobre a sua estrutura de organização, visando um método que suporte à decisão na avaliação da qualidade de sementes oleaginosas.

1.1 Motivação e Contextualização

Projeções da Organização das Nações Unidas (ONU) indicam que a população mundial atingirá a marca de 9,8 bilhões de habitantes até 2050, exigindo uma maior produção agrícola para atender às necessidades energéticas assim como a segurança alimentar¹ e a segurança do alimento². Desta forma, o crescimento da produção no setor agroalimentar se tornou imperioso. Portanto, buscar novas formas de aumentar a produção e a qualidade dos insumos como, por exemplo, a redução do uso de sementes danificadas durante a operação de plantio passou a ter grande relevância. Somado a esses fatores, há necessidade do uso de técnicas que possam garantir a segurança do alimento durante a fase de consumo.

As sementes de boa qualidade auxiliam no processo produtivo, economizam mão de obra e usam de forma minimizada os insumos para a produção (água, fertilizantes, agrotóxicos) na área agrícola (SANTOS, 2009). Também, devido à boa qualidade, o seu potencial de germinação é maior, agregando valor para a produção de óleos essenciais. Entretanto, quando as sementes apresentam defeitos, os quais são associados às trincas, às quebras, aos vazios internos, dentre outros, ocorre um prejuízo no seu potencial germinativo. A presença de sementes defeituosas nos locais de plantio leva à redução da produção provocando perdas econômicas e perdas na disponibilidade de óleos essenciais.

É importante observar que esses defeitos nas sementes oleaginosas podem estar em uma

¹ Segurança alimentar: Assegurar a quantidade de alimentos a uma população (demanda por alimentos).

² Segurança do alimento: De acordo com o *Codex Alimentarius*, um alimento seguro é aquele que proporciona segurança no seu consumo. Esse alimento não deve causar dano ao consumidor quando preparado ou ingerido intencionalmente.

escala que não permitem visualização a olho nu, assim como a sua observação em fotografias ou imagens obtidas no espectro da luz visível. Desta forma, há motivação para o uso da tomografia de raios-X em alta resolução (TC), o que pode viabilizar com maior grau de detalhe a natureza dos defeitos nas sementes oleaginosas, abrindo o caminho para o estabelecimento de um método para a classificação e para a separação entre as sementes prontas para o plantio e as sementes defeituosas.

A chegada da *Agricultura de Decisão*, que incorpora tecnologias avançadas no campo, provocou uma revolução nos processos, métodos e sistemas de manejo agrícolas (BARLETT, 2016; NETO, 2017). Exemplos de técnicas para melhorar a eficiência de manejo agrícola se encontram no âmbito da visão computacional. Esses métodos podem ser aplicados de forma não invasiva e não destrutiva (CRUVINEL et al., 1999; TAKEDA et al., 2003; PASSONI, 2013). Nesse contexto, foram encontrados inúmeros métodos não invasivos relacionados ao manejo agrícola como, por exemplo, o uso de imagens de ressonância magnética (JÚNIOR; YAMASHITA, 2001), o uso de imagens hiperespectrais (JÚNIOR et al., 2002), o uso de imagens óticas (FRANÇA et al., 2007), dentre outros que também podem ser utilizados (MINERVINI et al., 2015).

Adicionalmente, outros estudos indicam que as imagens óticas também podem ser aplicadas em áreas como a agricultura para as avaliações geomorfológicas pelo fato de fornecerem informações sobre as características físico-químicas do objeto capturado (ROSOT, 2001; FRANÇA et al., 2007). No caso das imagens hiperespectrais, devido ao fato delas proporcionarem um maior número de bandas contíguas, elas promovem o reconhecimento de matérias e propriedades físico-químicas (DAMASCENO et al., 2007). Ainda na área agrícola, as imagens de ressonância magnética têm sido utilizadas com sucesso na inspeção de raízes de plantas (DUSSCHOTEN et al., 2016; PFLUGFELDER et al., 2017). Entretanto, são encontrados poucos documentos referentes à classificação de sementes agrícolas para o plantio de forma não invasiva e não destrutiva com o uso da visão computacional (CHENG; YING, 2004; MONDO; CICERO, 2005; ARAUJO et al., 2011). Por conseguinte, os aspectos abordados neste presente trabalho contextualizam-se como uma boa oportunidade de pesquisa, o que promove a motivação para se aplicar a visão computacional e as técnicas avançadas de classificação utilizadas no processamento digital de imagens.

1.2 Objetivos

1.2.1 Objetivo Geral

Este trabalho pretende desenvolver um método de visão computacional para a classificação de imagens tomográficas, em alta resolução, de amostras de sementes oleaginosas boas e defeituosas para o plantio. Para isso, foram utilizadas as técnicas de processamento digital de imagens e as análises dos componentes principais.

1.2.2 Objetivos Específicos

De forma a atender o objetivo geral, os seguintes objetivos específicos foram considerados:

- Avaliação do uso da técnica de TC para a observação de defeitos de sementes agrícolas oleaginosas em escala de micro resolução.
- Avaliação do uso da técnica de TC para a observação de defeitos de sementes agrícolas oleaginosas em escala de micro resolução.
- Utilização de métricas para a avaliação da qualidade de filtragem e dos erros associados.
- Avaliação de técnicas para as definições das regiões de interesse para a segmentação, de forma a separar os objetos da cena.
- Avaliação de técnicas para a extração de características e o reconhecimento de padrões baseados em gradiente de magnitude, gradiente de direção e nos momentos invariantes.
- Avaliação do uso da técnica de Análise de Componentes Principais para a redução da dimensionalidade do conjunto de dados obtidos com o uso de descritores.
- Avaliação de técnica de Classificação para realizar a aprendizagem de dados, a identificar padrões de sementes agrícolas e respectiva distribuição em classes.

1.3 Considerações Finais

Com base no objetivo geral e nos objetivos específicos estabelecidos, este trabalho busca avaliar o uso da TC, em alta resolução, associado às técnicas de visão computacional e ao processamento de imagens para a classificação de sementes oleaginosas com e sem defeitos. Como resultado, duas classes distintas de sementes foram consideradas, ou seja, uma classe apresentou imagens tomográficas, em alta resolução, de amostras de sementes agrícolas adequadas para o plantio, enquanto a outra classe conteve as imagens tomográficas, em alta resolução, de amostras de sementes agrícolas que apresentaram defeitos acima de um limiar mínimo aceitável.

Este trabalho está estruturado de forma que o Capítulo 1 tratou da motivação e da contextualização da pesquisa. No Capítulo 2, será apresentado uma revisão de trabalhos relacionados à TC, aos fundamentos da visão computacional e às técnicas do processamento digital de imagens. As abordagens relativas à aplicação e à oportunidade no uso dessas técnicas na agricultura também serão vistas. No Capítulo 3, serão expostos os fundamentos matemáticos das técnicas relacionadas ao escopo desta dissertação cujas escolhas foram decorrentes das avaliações dos trabalhos apresentados na literatura utilizada, conforme foi visto nesse Capítulo, a fim de definir o método para a classificação de sementes agrícolas oleaginosas. No Capítulo 4, será descrito o

desenvolvimento do método para a classificação de sementes agrícolas baseado no uso de TC em alta resolução, nas técnicas de processamento de imagens digitais e na análise de componentes principais. Por fim, no Capítulo 5, serão apresentados os resultados, as discussões e as conclusões, assim como também serão demonstradas as sugestões para trabalhos futuros.

Capítulo 2

TRABALHOS CORRELATOS

Este capítulo apresentará a revisão da literatura em estado da arte. Os métodos da visão computacional envolvem conceitos relacionados à captura e à aquisição de imagens, às métricas de avaliação da qualidade de imagens, aos filtros para a melhoria da relação Sinal/Ruído, aos classificadores e às técnicas de visualização. Essa revisão bibliográfica foi desenvolvida utilizando *string* de palavras chaves e sua verificação junto às seguintes bases bibliométricas: *Google Scholar*, *IEEE Xplore*, *Precision Agriculture*, *Scopus*, *Springer* e *Web Of Science*.

2.1 Técnicas da TC de raios-X e Aplicações

A técnica de TC viabiliza de forma não invasiva a geração de imagens de secções transversais de um corpo sob estudo, as quais são conhecidas como fatias tomográficas. Baseado nessas fatias tomográficas são possíveis estabelecerem visualizações 2D, assim como 3D, utilizando algoritmos adequados.

O início da tomografia computadorizada foi relatado em diversos momentos e fatos. Em 1917, o matemático Johann Radon desenvolveu uma fórmula matemática para a reconstrução de corpos a partir de suas projeções (RADON, 1917). No ano de 1963, desconhecendo o trabalho do matemático Radon, o físico Allan MacLeod Cormack desenvolveu um modelo matemático para a reconstrução de um corpo com base em um número finito de projeções, permitindo a visualização da seção transversal do interior do corpo humano de maneira não invasiva (CORMACK, 1963; HOUNSFIELD, 1973). Essa técnica possibilitou a análise e a inspeção detalhada de uma imagem bidimensional ou tridimensional.

A partir dessa história, por ter sido predominantemente usada em aplicações médicas, a TC passou a ser aplicada em diferentes áreas além da medicina. Outras aplicações que citaram o uso da TC para diagnóstico envolvem, por exemplo, a ciência dos materiais (SALVO et al., 2003; MIDGLEY; DUNIN-BORKOWSKI, 2009), a botânica (STUPPY et al., 2003), a zoologia (PAULUS et al., 2000; LORIGADOS, 2008), a geologia (CARDARELLI; FISCHANGER, 2006; PICOZZI et al., 2009), a eletrônica (HOLDER, 2004), a mecânica (LUKAS, 2012), a odontologia (Capelozza Filho et al., 2005), a farmácia (DIOGO et al., 2014), a área agrícola, dentre outras.

Na década de 80 houve o surgimento das primeiras aplicações da TC na agricultura. Os trabalhos de Petrovic e colaboradores (PETROVIC et al., 1982), de Hainsworth e Aylmore (HAINSWORTH; AYLMORE, 1983), de Crestana e colaboradores (CRESTANA et al., 1985) foram considerados pioneiros. Todo o embasamento teórico proposto por esses autores teve o seu estudo aplicado na área da ciência do solo, mais especificamente no processo de infiltração de água no solo e nas características físicas como a densidade, a umidade e a porosidade.

Em 1987, Cruvinel e colaboradores desenvolveram, na Embrapa Instrumentação, o primeiro minitomógrafo baseado em fontes de raios-X e raios γ destinado às aplicações nas ciências do solo e das plantas (CRUVINEL, 1987; CRUVINEL et al., 1990). Derivados desse desenvolvimento do minitomógrafo e de outros trabalhos pioneiros, outros trabalhos de pesquisas voltados para aplicação de técnicas da TC, na área agrícola, têm sido apresentados. Dentre esses, se encontram os trabalhos de Crestana e colaboradores, que apresentaram uma análise da distribuição de densidade e umidade do solo utilizando a tomografia de raios-X e raios γ (CRESTANA et al., 1992). Em 1994, Naime apresentou um tomógrafo portátil, de primeira geração, para a análise de solo e de plantas (NAIME, 1994). Já Biassusi e colaboradores utilizaram um tomógrafo de feixe duplo para analisarem a densidade de um vertissolo (BIASSUSI et al., 1999).

Em 2008, Laia e Cruvinel aplicaram um filtro Kalman e as redes neurais para melhorarem a qualidade das projeções tomográficas de raios-X (LAIA et al., 2008). Nos anos subsequentes, houve maior atenção com os algoritmos de reconstrução de imagens e visualização, assim como ocorreu com os desempenhos nos processos de reconstrução (CRUVINEL et al., 2009; PEREIRA; CRUVINEL, 2015).

Outros trabalhos que merecem destaque utilizaram a microtomografia de alta resolução em problemas agrícolas para a análise tridimensional dos poros em microescala (REIS, 2011; VAZ et al., 2011; BERALDO et al., 2014). Nesse sentido, verifica-se que há o interesse de utilizar a TC de alta resolução nesse trabalho para que seja capaz de visualizar e interpretar toda a estrutura interna das sementes agrícolas. Com isso, é possível verificar as imperfeições físicas (defeitos) internas de cada semente agrícola cuja visibilidade no espectro visível não seja possível visualizar.

2.2 Técnicas de aquisição de imagens

As técnicas de aquisição de imagens fazem parte das etapas envolvidas no processamento de imagens digitais. Essas técnicas, viabiliza a aquisição de sinais de diferentes tipos de sensores e sua transformação para o meio digital.

Litos e colaboradores construíram um sistema sincronizado para capturar imagens em tempo real utilizando câmeras de baixo custo (LITOS et al., 2006). Para realizar a sincronização das câmeras, foi proposto o método de envio de mensagens, estabelecendo assim o tempo de

aquisição das imagens e a sincronização NTP (*Network Time Protocol*). Caso viesse a perder o tempo de sincronização, o sistema contaria com um sinal de erro em relação à latência de LAN (*Local Area Network*), ao tráfego e à largura de banda. Nesse contexto, o sistema de captura de imagens foi dividido em duas partes, sendo a primeira os servidores da câmera e a segunda o cliente. Os servidores da câmera ficavam em apenas um computador, sendo que cada computador possuía uma ou mais câmeras. Os clientes eram responsáveis por controlar a captura nas máquinas, desde que houvesse uma conexão de rede. O sistema de captura das imagens foi feito através de câmeras idênticas, elas eram controladas por uma estação de controle. Assim, o sistema viabilizava o envio de mensagem a todos os servidores, avisando o tempo que iria ocorrer a aquisição das imagens e executando, dessa forma, a captura do alvo em todas as estações ao mesmo tempo.

Em 2010, Hang utilizou os processadores DSP¹ para projetar e implementar um sistema de aquisição e identificação de imagens simultaneamente (HANG, 2010). O DSP é um microprocessador e apresenta a sua estrutura em software e em hardware que podem ser utilizados em operações envolvendo o tempo real. Para realizar a captura e o processamento, utiliza-se periféricos como a câmera CCD, o processador TMS320DM643, a fonte de alimentação, o computador host e o emulador. Nesse trabalho, a captura das imagens foi gerada pela observação da projeção entre a cena e o sensor. Outros dois aspectos que foram relevantes: a utilização da segmentação por região e a segmentação de borda para separar o objeto da cena; e o uso do método de esqueletização para a realização de identificação das imagens.

Liu e colaboradores construíram um sistema de aquisição, exibição e armazenamento de imagens utilizando o processador embarcado ARM² (Sistema operacional Linux), com baixo custo de energia e de pequeno tamanho (LIU et al., 2011). Além do sistema operacional utilizado, foram usados componentes de hardware como a câmera USB com o sensor de captura da cena, o monitor LCD para a exibição e a memória para armazenamento das imagens. Também, consideraram comparações de partes dos periféricos utilizados nesse projeto. Todo o processo se iniciava com a coleta feita pela câmera, seguindo para o processador ARM9 para que assim fosse feito todo o processamento e a compilação chamando os programas de armazenamento e exibição. Os resultados desses sistemas mostraram rapidez e clareza para a exibição das imagens, além do baixo custo e alto desempenho do processador.

Morozkin e colaboradores construíram uma arquitetura de aquisição de imagens para os sistemas de rastreamento ocular (MOROZKIN et al., 2015). Nessa proposta, esses autores utilizaram um microcontrolador ARM, FPGA³ e memória RAM⁴ externa na composição do respectivo sistema. A aquisição das imagens se iniciava através do sensor de uma câmera

¹ DSP: sigla do inglês *Digital Signal Processor*, trata-se de um microprocessador utilizado para processar em tempo real imagens, áudios, vídeos, etc.

² ARM: sigla do inglês *Acorn RISC Machine*, trata-se de é uma plataforma de processador.

³ FPGA: sigla do inglês *Field Programmable Gate Array*, trata-se de um circuito integrado.

⁴ RAM: sigla do inglês *Random Access Memory*, trata-se de um *hardware* de armazenamento volátil.

externa, onde as imagens com resolução 640x640 *pixels* eram capturadas utilizando a FPGA e armazenadas em memória RAM externa. Sendo assim, para realizar a leitura das imagens, os autores utilizaram um *buffer* de Entrada/Saída interno para efetuar a leitura de uma imagem inteira, assim, esse *buffer* contendo os dados viabilizou o armazenado no Computador. Com as imagens salvas na memória do computador, a transmissão delas para o local de tratamento no host foram feitas considerando o uso de comunicações por conexões USB⁵, WiFi⁶ e Ethernet⁷. Todo o sistema de aquisição das imagens foi executado separadamente dividindo cada tarefa em subtarefas. Nesse caso, essas subtarefas foram executadas em software e hardware, utilizando MCU⁸, FPGA e a comunicação em formas diversas. Considerando as diferentes formas de comunicação, as decomposições das tarefas e a execução em subtarefas, os autores relataram situações em que ocorreram os maiores ganhos de desempenho.

Recentemente, Xiu e colaboradores usaram um smartphone e técnicas de visão computacional para proporem um algoritmo de aquisição de imagens em diferentes ambientes (XIU et al., 2018). Dessa forma, apresentaram um algoritmo adaptativo possibilitando melhorias associadas à região de captura dessas imagens. As imagens com baixa qualidade passaram por um processo de filtragem para melhorar a qualidade. Toda a metodologia apresentada por esses autores contou com o sensor de câmera, a memória e o CPU de smartphone, além de um Algoritmo Adaptativo para o ajuste de Resolução (*Resolution Adaptive Algorithm* - RAA).

2.3 Técnicas de pré-processamento de imagens

As técnicas de pré-processamento de imagens referem-se ao processamento inicial de sinais a partir de sensores que foram convertidos para o meio digital. Esses processamentos, por exemplo, são utilizados para calibração radiométrica de imagens digitais, correção de distorções geométricas e melhorias na relação Sinal/Ruído. Nesse contexto, essas técnicas visam o aprimoramento da qualidade de imagens para etapas subsequentes do processamento.

Cruvinel e colaboradores apresentaram um método baseado em técnicas do processamento de imagens para analisarem o tamanho e identificarem a distribuição de gotas de chuva, natural e artificial, no solo e em plantas (CRUVINEL et al., 1999). Para realizarem essa análise de forma eficiente, esses autores utilizaram os métodos de reconhecimento de padrões baseados no uso da transformada de Fourier e da correlação no domínio da frequência. Nesse contexto, foi utilizado para o reconhecimento de padrões o produto da imagem de entrada com os padrões de gotas. Para a geração dos padrões de calibração, os autores utilizaram volumes variando de 0,0054 até 0,0810 cm³, com diâmetros variando entre 1,2 a 1,5 mm, respectivamente. Com essas informações sobre o tamanho e a distribuição das gotas, foram calculadas a fração de

⁵ USB: sigla do inglês *Universal Serial Bus*, trata-se de uma porta universal que permite a conexão de periféricos.

⁶ Wifi: dispositivo de rede local, para conexão sem fio.

⁷ Ethernet: arquitetura de rede local.

⁸ MCU: pequeno microcontrolador feito em um único circuito integrado.

gotas dentro de um intervalo e a distribuição acumulativa em função do tamanho. Com isso, foi instituído a viabilidade do método e o seu uso em agricultura.

Em 2001, Demirkaya apresentou em seu artigo uma avaliação da qualidade do filtro de difusão anisotrópico não linear aplicado a uma imagem degradada por um ruído estatístico (DEMIRKAYA, 2001). Nesse contexto, foram utilizadas imagens tomográficas bidimensionais obtidas antes do processo de reconstrução. Portanto, cada imagem tomográfica passou por um processo de adição de um ruído do tipo Gaussiano, de modo que a variação da distribuição gaussiana era feita de forma adaptativa. Com isso, conforme os resultados obtidos mediante à métrica *Signal- to-Noise Ratio* (SNR), mostrou-se que o uso do filtro de difusão anisotrópica em imagens TC foi eficaz em termos de redução de ruído Gaussiano.

Buades e colaboradores apresentaram uma comparação quantitativa e qualitativa de um novo algoritmo para a redução de ruído em imagens digitais (BUADES et al., 2005). Tal algoritmo proposto, chamado *Non-Local Means* (ou médias não locais), foi comparado a outros métodos de redução de ruídos presentes na literatura, como o filtro de suavização e difusão anisotrópica (PERONA; MALIK, 1990; ALVAREZ et al., 1992), a minimização da variação total (RUDIN et al., 1992), o Gaussiano (LINDENBAUM et al., 1994) e a vizinhança (SMITH; BRADY, 1997; TOMASI; MANDUCHI, 1998). Logo, antes de realizar a comparação dos métodos, todas as imagens passaram por um processo de adição de ruído aditivo branco para serem avaliadas. Consequentemente, os resultados obtidos mediante à métrica Erro Médio Quadrático, mostraram a superioridade do método *Non-Local Means* em relação aos demais métodos utilizados no trabalho.

Miranda e Camargo usufruíram do modelo de difusão anisotrópica para a detecção de bordas em imagens digitais (MIRANDA; NETO, 2007). As bordas são regiões que definem o contorno de um objeto, sendo elas as fronteira do objeto em uma cena. Porém, em imagens digitais reais existem ruídos que produzem variações nos valores dos *pixels* que dificultam o processo de encontrar bordas bem definidas. Sendo assim, os autores utilizaram o filtro para suavizar a imagem, preservando sua borda original e removendo o ruído intra-regiões. O modelo de difusão anisotrópica utilizado por esses autores consideraram uma imagem original $I(x,y)$ e a convolução com o filtro gaussiano $G(x,y;t)$, resultando em uma imagem derivada $I(x,y;t)$ com variância de tempo t . Os resultados obtidos por esses autores mostraram que quando havia um aumento no número de iterações, as bordas eram mantidas e os detalhes intra-regiões se perdiam.

Coser e colaboradores apresentaram uma melhoria no filtro de difusão anisotrópica usando um mapa de gradientes e uma adaptação do parâmetro de definição das bordas, conhecido como parâmetro λ (COSER, 2009). Assim, foi estabelecido um auxílio ao processo de suavização, além de que foi possível definir quais bordas deveriam ser preservadas após a realização de um certo número de iterações. Nesse contexto, os mapas de gradientes, que são máscaras com simetria positiva, podem ser aplicados junto à equação de filtragem anisotrópica (BROX et al., 2006). Com isso, houve uma garantia em relação à variação do gradiente caso fosse anulado.

Adicionalmente, os autores empregaram o fator λ adaptativo que teve como função estabelecer a capacidade de esmaecimento dos *pixels* em uma borda. Sendo assim, após os testes os autores concluíram que o uso de duas heurísticas foram eficazes em termos de filtragem e preservação de bordas.

Giraldo e colaboradores apresentaram em seu artigo uma comparação quantitativa de duas técnicas de filtragem não lineares para a redução de ruídos em imagens da TC (GIRALDO et al., 2009). Seguindo esse âmbito, as imagens tomográficas desse trabalho foram obtidas utilizando um scanner de fonte dupla, modelo *Siemens Definition DS*. Logo, após o processo de obtenção das imagens tomográficas, os autores aplicaram os filtros *Non-Local Means* (NLM) e *Bilateral* (BF). Desse modo, os filtros foram utilizados para comparar a resolução espacial e a detectabilidade de baixo contraste em relação ao algoritmo de *Weighted Filtered Backprojection* (WFBP). Com essa abordagem, os autores constataram que os filtros NLM e BF apresentaram uma resolução espacial de alto contraste e uma melhora na redução de ruído, quando comparados ao algoritmo WFBP.

Attivissimo e colaboradores apresentaram, em seu artigo, uma avaliação utilizando diferentes técnicas de filtragem de ruído estatístico em imagens obtidas pela tomografia computadorizada (ATTIVISSIMO et al., 2010). Nesse parâmetro, para realizar essa avaliação de forma eficiente, cada imagem passou por um processo de adição de ruído do tipo Gaussiano. Em seguida, os autores aplicaram duas técnicas de filtragem. A primeira utilizada foi a combinação de operadores Gaussiano e *Prewitt*, para a detecção de bordas. A segunda usada foi o filtro passa-baixa de difusão anisotrópica, ele foi aplicado para reduzir o ruído e para preservar as bordas da imagem. Contudo, após o cálculo do e^{RMS} , os autores concluíram que a combinação das duas técnicas de filtragem foram capazes de aumentar a qualidade e reduzir a contribuição do ruído nas imagens.

No ano de 2013, Santiago apresentou a utilização do filtro de difusão anisotrópica e da morfologia matemática em imagens de alta resolução para detectarem feições cartográficas, em rodovias e corpo d'água, da região de São Paulo (SANTIAGO, 2013). As imagens desse trabalho foram obtidas através de satélites com alta resolução. Em seguida, o autor aplicou após a aquisição das imagens dois métodos de suavização. O primeiro utilizou o filtro de difusão anisotrópica para a suavização em áreas homogêneas e para a preservação das bordas da imagem. O segundo usou a morfologia matemática considerando o uso de equações diferenciais parciais para realizar a suavização, sendo as mesmas consideradas como operadores específicos para a detecção das bordas da imagem. Com essa abordagem dos dois métodos considerados, o morfológico foi o que se mostrou mais eficiente para a detecção de feições.

2.4 Principais métricas para análise de imagens

As métricas para análise de imagens são utilizadas para definir o tipo de filtragem a ser utilizada para o auxílio à restauração de imagens digitais ruidosas ou degradadas. Essas métricas estão associadas a qualidade de imagem (do inglês *Image Quality Measures - IQM*). As *IQM*. As *IQM* são descritas como um modelo de avaliação que visa medir a qualidade de degradação, de restauração e de compressão entre duas imagens.

Na literatura existem dois métodos para essas avaliações, sendo eles: o subjetivo e o objetivo. A avaliação subjetiva é realizada por seres humanos que julgam a qualidade das imagens exibidas através de suas informações visuais (ZAMPOLO et al., 2008; DEVNANI; RAWAT, 2016). A avaliação objetiva tem como propósito avaliar automaticamente a qualidade de uma imagem através de funções matemáticas (ou métricas) (THUNG; RAVEENDRAN, 2009). As métricas objetivas são classificadas em três categorias: a referência completa (FR, do Inglês *Full Reference*), que fornece informação completa da imagem original e da imagem corrompida; a referência reduzida (RR, do inglês *Reduce Reference*), que fornece a instrução sobre a imagem corrompida e apenas a parte da informação da imagem original; e, por fim, a sem referência (NR, do inglês *No Reference*), que fornece apenas informação da imagem corrompida.

Na literatura da área, utilizando essas métricas, Zampolo e colaboradores propuseram uma metodologia para avaliarem e compararem a qualidade de imagens após a adição do ruído Gaussiano (ZAMPOLO et al., 2008). Nesse trabalho, especificamente as métricas objetivas aplicadas foram a Razão Sinal-Ruído (SNR) e a Pico da Razão Sinal-Ruído (PSNR), as quais são classificadas como métricas não perceptuais. Esses autores também utilizaram as métricas perceptuais de Similaridade Estrutural Média (MSSIM, do inglês *Mean Structural Similarity Index Measure*), de Critério de Fidelidade de Informação (IFC, do inglês *Information Fidelity Criterion*), de Fidelidade de Informação Visual (VIF, do inglês *Visual Information Fidelity*) e de C4. Na avaliação objetiva, os autores utilizaram um modelo matemático que realiza a comparação entre a imagem referente com a imagem teste. Dessa forma, esses autores estabeleceram um método que pode substituir a inspeção humana.

Em 2009, Thung e Raveendran desenvolveram um artigo de revisão da literatura sobre as atuais métricas subjetivas e objetivas, agrupando-as de acordo com as suas estratégias e técnicas (THUNG; RAVEENDRAN, 2009). O principal foco foram as métricas objetivas (FR), devido à rapidez e ao baixo custo prático em relação às métricas subjetivas. Sendo assim, foram abordadas as métricas matemáticas como MSE e PNSR, as métricas baseadas em sistema de visão humana e as outras como a métrica SSIM. Como resultado, esses autores constataram que a métrica SSIM possui uma baixa complexidade computacional e uma correlação com a métrica subjetiva.

Em 2012, Gubern-Merida e colaboradores propuseram um estudo para avaliar o desempenho do método de segmentação baseado em um modelo probabilístico e multi-atlas, aplicando-o em imagens de Ressonância Magnética do músculo peitoral (GUBERN-MÉRIDA et al., 2012).

O primeiro método baseado no modelo probabilístico utilizou uma estrutura bayesiana, de forma que a distribuição das probabilidades identificava as áreas pertencentes à região do peitoral e à região torácica do paciente. O segundo método, chamado multi-atlas, mapeava e identificava a região de interesse utilizando o algoritmo de registro, em seguida realizava a correlação cruzada com os outros atlas que possuíssem similaridade. Nesse contexto, os métodos foram avaliados utilizando a métrica matemática DSC, de forma a estabelecer uma relação entre a separação do objeto da cena. Sendo assim, os autores concluíram que o método multi-atlas proporcionou um desempenho ligeiramente melhor comparado ao método probabilístico.

Em 2016, Devnani e Rawat propuseram uma análise comparativa das *IQM* aplicadas em imagens digitais (DEVNANI; RAWAT, 2016). Os modelos analisados nessa pesquisa foram: o MSE e o PSNR; e o SSIM e o VIF. Os experimentos foram divididos em duas partes. Na primeira, uma imagem foi submetida a um ruído impulsivo para a degradação da qualidade. Logo, em seguida, a imagem passou por uma técnica de filtragem, onde foi aplicado o filtro da mediana para reduzir o ruído. Na segunda, a imagem foi submetida a um ruído Gaussiano branco, ou seja, ela passou por uma técnica de filtragem em que foi aplicado o filtro de Wiener. Com a realização dos dois experimentos, os autores concluíram que a métrica VIF apresentou um resultado melhor que aquele obtido com a métrica PSNR, pois a mesma se baseou em uma abordagem estatística aplicada em uma cena natural.

2.5 Técnicas de segmentação de imagens

A segmentação de imagens digitais são técnicas utilizadas para dividir uma imagem digital em múltiplas regiões que formam um conjunto de *pixels*, ou para separar objetos com o objetivo de facilitar a sua análise.

Skalnsky fez uma abordagem sobre as técnicas de segmentação e extração de características, incluindo as diretrizes e os exemplos referentes ao assunto (SKLANSKY, 1978). Esse autor considerou as técnicas de segmentação de imagens como um dos elementos principais da área de visão computacional. A segmentação de imagens consiste em detectar limites (traços ou bordas) e analisar a textura de objetos dentro de uma imagem. Por outro lado, a extração de características está associada à retirada de informações de cada parte segmentada de uma imagem utilizando um vetor numérico para representá-la.

Onyango e Marchant desenvolveram um algoritmo de segmentação de imagem baseado em cor e morfologia (ONYANGO; MARCHANT, 2003). As imagens utilizadas estavam relacionadas à cultura de plantas de couve-flor, às ervas daninhas e ao solo. Nesse caso, os autores utilizaram a informação contextual combinando o parâmetro cor e a distribuição espacial de *pixels*, separando, assim, as plantas de ervas daninhas. Ainda, nesse contexto, o processo do algoritmo de segmentação foi definido por dois conjuntos, um deles foi para as plantas e o outro para solo. Além disso, o conjunto de plantas foi subdividido em componentes referentes à cultura

e às plantas daninhas.

Espíndola e colaboradores desenvolveram um algoritmo de segmentação por crescimento de região baseado na homogeneidade e nas propriedades de forma (ESPINDOLA et al., 2006). Os critérios adotados pelos autores para tratar os parâmetros da homogeneidade foram baseados em estimativas, a partir da seleção de forma sequencial dos locais da amostra, na região da imagem. Nesse contexto, a abordagem adotada nesse trabalho utilizou os *pixels* com os menores comprimentos de gradientes pertencentes à região da imagem que não foi segmentada como um ponto de propagação. Esse algoritmo possibilitou a aplicação de limites de similaridades e de limites de áreas para que o agrupamento dos *pixels* vizinhos ocorresse quando houvesse uma semelhança entre eles. Contudo, o método de segmentação desses autores passou a ser entendido como um método totalmente automático.

Ming, em 2010, fez uma demonstração da utilização de algoritmo genético para a segmentação de imagens (MING, 2010). Tal abordagem possibilitou otimizar e buscar maior eficiência no processo de segmentação. Nesse caso, o processo foi iniciado utilizando o método de Otsu (OTSU, 1979), no qual a partir do histograma da imagem foi estabelecido um limiar. O algoritmo genético buscou um valor ótimo de um limiar dentro de um intervalo pré estabelecido. Com o uso desse algoritmo genético para segmentar uma imagem, o autor concluiu melhorias em relação ao tempo de cálculo do limiar e de sua estabilidade.

Chauhan e colaboradores apresentaram uma abordagem sobre os métodos que realizaram a segmentação de imagens, sendo eles: a segmentação por detecção de borda, *threshold*, e a segmentação por região e clusterização (CHAUHAN et al., 2014). O método estabelecido por esses autores, de detecção de bordas, apresentou a propriedade de descontinuidade, onde havia uma fronteira na imagem que a separava em duas regiões. Quanto ao uso do *threshold*, os autores usaram um valor de intensidade para comparar com os *pixels* da imagem, portanto, cada vez que acontecia uma comparação, era identificado se o valor daquele *pixel* na respectiva posição (x, y) era maior ou igual ao limiar considerado como parte do objeto, caso contrário, seria considerado como *background*. O método de segmentação orientado à região consistiu em particionar a imagem baseando-se em características de cores, de textura, etc. Por último, no método de segmentação baseado em clusterização, a imagem foi dividida em grupos onde cada um se assemelhava ao objeto ou ao fundo. Esses autores ainda apresentaram os métodos de clusterização existentes como, por exemplo, o método K-Means (HARTIGAN; WONG, 1979), que é popular entre os outros de clusterização. O uso do K-Means teve por objetivo dividir a imagem em k clusters e cada cluster foi representado por um centroide, que tratou da média de intensidade de *pixels* contidos nos clusters. Todas essas abordagens e conceitos apresentados por esses autores mostraram a importância de cada técnica específica para realizar a segmentação.

Kuruvilla e colaboradores retratam em seu artigo as principais técnicas de segmentação, na área da visão computacional (KURUVILLA et al., 2016). Semelhante aos métodos de segmentação citados por Chauhan e colaboradores, os autores descreveram como é feita a aplicação

dos métodos na área do processamento de imagens (CHAUHAN et al., 2014). Dentre essas aplicações, foram consideradas: a melhoria do contraste e restauração de imagem, onde foram utilizadas transformações de intensidades e filtros para restaurar as imagens degradadas; a compressão de imagem para realizar a compactação e compatibilização às redundâncias em imagens; o reconhecimento de caractere, tendo como objetivo identificar e extrair informações textuais; a verificação de assinatura para realizar autenticação pessoal; a biometria. Por conseguinte, foi concluído, por esses autores, que não existe um único método de segmentação de uso geral quando se considera a variedade de objetos e imagens.

Sood e colaboradores apresentaram uma abordagem utilizando técnicas de processamento de imagens para detectarem trincas internas em imagens tomográficas de sementes de feijão (SOOD et al., 2016). Nesse contexto, o artigo demonstra uma combinação de técnicas provenientes da limiarização pelo histograma e dos operadores morfológicos. Desse modo, a partir da aquisição de uma imagem tomográfica, os autores utilizaram um filtro de mediana para a remoção do ruído impulsivo. Sendo assim, após o processo de suavização, cada *pixel* da imagem era comparado a um limiar T para determinarem o *pixel* pertencente à semente ou ao fundo da imagem. A partir da separação da semente em relação ao fundo da imagem tomográfica, houve a aplicação dos operadores morfológicos de erosão e de dilatação para removerem as pequenas intrusões obtidas na segmentação de limiarização. Contudo, os autores concluíram a eficiência do método em detectar trincas internas em sementes agrícolas que não são visíveis em ambientes externos.

Souza e colaboradores apresentaram uma abordagem usando o conceito de grafos para a segmentação de imagens (SOUZA et al., 2016). A partir dela, eles demonstraram uma combinação de técnicas provenientes da teoria de grafos e do método de filtragem de difusão anisotrópica. Nesse contexto, os autores contaram com as informações contextuais para a classificação de cada *pixel* da imagem. Sendo assim, a partir de uma imagem em tons de cinza, iniciaram a aplicação de um filtro de difusão anisotrópica para a suavização. Após a suavização, cada *pixel* da imagem foi conectado aos seus nós adjacentes, formando-se um grafo. A partir de um grafo, houve a utilização do algoritmo Ford-Fulkerson (FORD; FULKERSON, 1962) para a realização do corte mínimo do grafo e a separação dos objetos de interesse da cena.

Recentemente, Brito e Cruvinel apresentaram uma avaliação usando o conceito de grafos para a segmentação de imagens tomográficas de sementes oleaginosas (BRITO; CRUVINEL, 2020). Nessa abordagem, demonstraram uma combinação das técnicas provenientes da teoria de grafos e do método de extração de características geométricas. Desse modo, os autores contaram com os modelos matemáticos e os conceitos semânticos aplicados para a classificação de cada *pixel* da imagem. A partir das informações contextuais de cada *pixel* com seus nós adjacentes, iniciou-se a formação de um grafo. A partir de um grafo, houve a utilização do algoritmo Edmonds-Karp (EDMONDS; KARP, 1972) para realizar a busca em largura de todos os nós saturados e realizar o corte mínimo do grafo, separando todos os nós referentes aos objetos de

interesse da cena. Como resultado, os autores analisaram com a métrica SSIM que o método desenvolvido foi superior para a segmentação das imagens tomográficas de sementes oleaginosas, quando comparadas ao método Otsu.

2.6 Técnicas de extração de características

As técnicas utilizadas para a extração de características em imagens digitais determinam de forma apropriada e com uma certa dimensionalidade o conjunto de características de subespaços previamente determinados em fases anteriores do processamento. A definição de uma técnica adequada para a extração de características em imagens digitais é um dos fatores mais relevantes para a construção de um sistema de visão ou reconhecimento de padrões. As características devem destacar as diferenças entre objetos de classes distintas e minimizar possíveis diferenças entre objetos de mesma classe.

Em 1962, Ming-Kuei Hu apresentou, em seu artigo, uma teoria sobre momentos invariantes bidimensionais aplicados em figuras geométricas (HU, 1962). Fundamentados em modelos matemáticos e em processamento de informação visual, esses momentos se relacionam aos algébricos, aos centrais e aos ortogonais. Esses momentos invariantes foram baseados na invariância de transformações geométricas de escala, de translação e de rotação, portanto, úteis para reconhecer-se um conjunto de padrões em figuras geométricas planas. Além disso, a teoria aplicada nesse artigo permitiu calcular a área e o centro de massa do objeto, conseqüentemente realizando a identificação de um objeto. Nesse contexto, baseadas em momentos bidimensionais e em momentos centrais, o autor propôs sete equações de segunda e terceira ordem conhecidas como momentos invariantes de HU para reconhecerem padrões em caracteres alfabéticos. Os padrões utilizados pelo autor foram os números de 0 a 9 e as letras do alfabeto. Cada caractere utilizado nesse artigo foi representado por uma imagem bidimensional, com dimensão 16x16 *pixels* e cada *pixel* com o valor entre 2 a 8. Por conseguinte, cada padrão extraído foi classificado utilizando o cálculo da distância euclidiana para definir em qual classe representava o respectivo padrão.

Lu e Little apresentaram, em seu artigo, um sistema de rastreamento e reconhecimento de ações feitas por atletas utilizando apenas informações visuais deles (LU; LITTLE, 2006). O algoritmo utilizado pelos autores baseou-se na aplicação do descritor HOG juntamente com a técnica do PCA para que se realizassem o reconhecimento de ações postas pelos atletas. Posto isso, a metodologia aplicada com base no descritor HOG, por ser utilizada para rastrear visualmente e calcular toda a ação realizada pelo atleta, possibilitou centralizar a imagem do atleta na região de rastreamento deixando invariante as mudanças de iluminação. Logo após, a técnica aplicada pelo PCA teve como objetivo projetar os dados obtidos pelo método anterior em um subespaço linear. Com isso, ao aplicar os métodos HOG-PCA, o sistema tem um ganho em relação à velocidade de rastreamento e a uma maior precisão ao reconhecer as ações relacionadas

aos atletas sobe análise.

Ahmed e colaboradores utilizaram métodos de visão computacional para construir um sistema que realiza o controle de plantas invasoras em tempo real (AHMED et al., 2008). O objetivo desse sistema foi o de buscar detectar e identificar as plantas invasoras utilizando os métodos de visão computacional e o reconhecimento de padrão e o sistema robótico. Para realizar a detecção e a identificação, o sistema baseou-se na medição de densidade das plantas invasoras classificando-as em folhas largas ou folhas estreitas para realizar a aplicação da herbicida. Todo o sistema foi desenvolvido em Visual C ++ usando uma *Graphical User Interface* (GUI⁹) para promover a interação do usuário com o sistema. A base de dados conteve as imagens RGB, com resolução 340x240 *pixels*, sendo que na etapa de pré-processamento, as imagens RGB foram convertidas em imagens binárias, onde detectaram ervas daninhas com a tonalidade de *pixels* brilhantes e o fundo escuro. Após a etapa de pré-processamento, os autores aplicaram a técnica de classificação de densidade baseada, primeiramente, na porcentagem de ervas daninhas na imagem, através do cálculo da porcentagem de *pixels* claros sobre o total de *pixels* da imagem. Logo após, para calcular a densidade de ervas daninhas, aplicou-se uma máscara 9x7 em toda a imagem e avaliaram a sua porcentagem de *pixels* claros no interior da máscara. Com isso, o sistema classificou as 170 imagens de folhas largas e estreitas conjuntamente em 3 diferentes tipos de ervas daninhas mostrando-se uma precisão de 95% de acertos.

No mesmo ano, Santos e Cruvinel utilizaram técnicas do processamento de imagens e do reconhecimento de padrões para desenvolverem um sistema de reconhecimento de plantas invasoras, tanto de folhas largas quanto de folhas estreitas em ambientes agrícolas (SANTOS; CRUVINEL, 2008). Todo o trabalho foi dividido em etapas, as quais se abordaram sobre a aquisição de imagens utilizando uma câmera digital com 180 *pixels*/polegadas de resolução, apresentando uma imagem com o tamanho de 600x600 *pixels*. Após esse processo de captura das imagens, foi iniciada a etapa de pré-processamento sendo aplicado o filtro da mediana para suavizar os ruídos existentes nas imagens. A etapa de segmentação foi baseada em textura, onde foram divididas as imagens em pequenas regiões calculando as medidas estatísticas de textura adquiridas, por meio da matriz de co-ocorrência. A partir das imagens segmentadas, o processo final tratou sobre os descritores e o reconhecimento das plantas invasoras. Desse modo, foram aplicados os descritores de textura: a redondez, a solidez e a alongação. Cada descritor utilizou respectivamente informações extraídas da área, do perímetro, do comprimento, da largura e do menor polígono convexo do objeto. Para realizar o reconhecimento das plantas, foram feitos os cálculos com a média de cada descritor comparando com o valor de cada região. Baseado em todo processo para o reconhecimento de padrões de plantas invasoras, os autores concluíram que o descritor de alongação obteve o melhor resultado em relação ao demais, com uma taxa de acerto de 84,24% para as folhas largas e 80,17% para as folhas estreitas.

Relacionando aos teoremas de momentos invariantes algébricos, Huang e Leng propõe

⁹ GUI: interface gráfica que permite a interação do sistema com o usuário.

um estudo baseado em momentos invariantes às transformações geométricas (HUANG; LENG, 2010). Esse estudo, visou analisar empiricamente o efeito da imagem rotacionada e modificada por um fator de escala. Nesse contexto, outros estudos realizados com experimentos em várias imagens foram considerados, onde antes elas passavam por um processo de escala, de rotação e de translação. A partir dessas transformações, os autores perceberam que a transformação de escala e de rotação mudaram as funções e as propriedades da imagem levando aos erros dos momentos invariantes. Os experimentos foram realizados em duas imagens, cada uma com a dimensão de 250x250 *pixels* de resolução tendo uma variação de 10x10 a 500x500 *pixels*, com 10 incrementos. Continuando a fase de experimentos, para cada imagem foram aplicados os momentos invariantes de Hu e, em seguida, o cálculo de flutuação. Sendo assim, o cálculo da flutuação utilizou todos os dados extraídos pelos momentos invariantes de Hu, usando-os em sua equação a média, o valor máximo e o valor mínimo desses dados. Com todos esses experimentos, os autores também concluíram uma mudança que ocorreu quando se aplicou os momentos invariantes, em imagens expandidas e rotacionadas, devido ao fato das imagens não terem sido contínuas.

Chaki e Parekh desenvolveram um sistema de reconhecimento e classificação automático de plantas agrícolas (CHAKI; PAREKH, 2012). Nesse trabalho, todos os reconhecimentos foram realizados com base na geometria das folhas. Para tanto, foram aplicadas as técnicas de reconhecimento de formas baseadas em momentos invariantes de Hu. Adicionalmente, foram aplicadas ao método *Centroid-Radii* para extrair informações a partir de uma imagem, onde foram consideradas informações do centroide e das bordas do objeto. Também, esses autores aplicaram o método *Binary Superposition*, que tem uma abordagem mais simples em relação às outras duas técnicas utilizadas. Para o uso desse método, as imagens foram binarizadas e os *pixels* com valores diferentes de zero foram somados de forma a se obter o valor de similaridade, isto é, quanto maior foi o valor, maior foi a similaridade encontrada pelos autores. Os experimentos foram realizados com 60 imagens da classe *Arbutus unedo*, 60 imagens da classe *Betula pendula Roth* e 60 imagens da classe *Pittosporum tobira*. Portanto, foram utilizadas 120 imagens dessas três classes para o treinamento e 60 imagens para os testes. Com isso, entre os métodos e os experimentos abordados, o método *Centroid-Radii* viabilizou a obtenção de melhores resultados em relação aos outros métodos mencionados.

Em 2013, Miyamoto utilizou, assim como outros pesquisadores, os métodos de momentos invariantes de Hu e cálculos estatísticos para verificar e analisar a qualidade de mistura das fibras vegetais em amido termoplástico (MIYAMOTO, 2013). Nesse caso, ele utilizou imagens tomográficas das fibras vegetais de Acuri, de Gravatá e de Carandá, as quais foram obtidas através de um tomógrafo de raios-X de resolução micrométrica. Após a aquisição, foi realizada a análise e a avaliação da homogeneidade das imagens, através dos momentos invariantes de Hu. Em seguida, esse autor fez a verificação da qualidade e homogeneidade das fibras com base no uso de métodos estatísticos envolvendo medidas de variância, desvio padrão e coeficiente de variação de Pearson. Além disso, o autor desenvolveu uma interface gráfica para a interação

com o usuário e os módulos que foram desenvolvidos. Com isso, estabeleceu-se um método capaz de auxiliar na verificação da qualidade da produção e na extração de amostras agrícolas biodegradáveis.

2.7 Técnicas de reconhecimento e classificação de padrões em imagens

As técnicas utilizadas para o reconhecimento de padrões em imagens digitais, envolvem o uso de características que podem descrever ou estabelecer uma representação de padrões de objetos dessas imagens. As técnicas de reconhecimento de padrões devem ser capazes de reconhecer um objeto independentemente de sua orientação, tamanho e localização no campo de existência da imagem sob análise. Os classificadores são utilizados para classificar padrões que foram previamente estabelecidos, visando qualificar à qual classe o pertencem.

Em 2000, Tian e colaboradores utilizaram técnicas de visão computacional para desenvolverem uma máquina capaz de detectar e localizar as plantas daninhas em plantações de tomate (TIAN et al., 2000). Todo o processo de localização e identificação foi iniciado considerando a etapa de aquisição das imagens, sendo a captura das imagens retiradas de 13 campos pertencentes aos ambientes naturais agrícolas, usando nessa máquina uma câmera frontal e uma câmera colocada na parte de trás do equipamento, ambas operando em formato RGB de 24 bits e de resolução de 640x480 *pixels*. Também, esses autores utilizaram a função de identificar e diferenciar plantas de tomates e plantas daninhas. Com isso, os autores usaram as etapas de pré-processamento baseadas em cores e na segmentação através de um algoritmo de segmentação adaptativo (EASA do inglês - Environmentally Adaptive Segmentation Algorithm) para a separação das plantas do fundo da imagem. Consequentemente, esses autores identificaram e reconheceram os padrões nas imagens coletadas e promoveram a separação entre as classes utilizando o classificador Bayesiano. Como resultado, obtiveram 65% a 78% de acurácia para os tomateiros e menos de 5% para as plantas daninhas.

Em 2005, Granitto e colaboradores desenvolveram um sistema de visão computacional que possibilitou realizarem a identificação de sementes (GRANITTO et al., 2005). As características das sementes utilizadas foram extraídas com base em cores, tamanhos, formas e em texturas. Essas identificações ocorreram no espectro visível. Assim, as características dessas sementes foram agrupadas em grupos morfológicos, nos texturais e nas cores. Após essas sementes serem separadas em grupos, os autores utilizaram classificadores Naïve Bayes (NB) e RNA *feedforward*. O papel do classificador NB, por ser probabilístico, foi classificar de forma independente cada espécie de semente. A RNA foi estabelecida utilizando uma rede com 12 neurônios de entradas (referentes à quantidade das espécies de sementes) e nas camadas ocultas foram testadas entre 20 a 100 camadas de neurônios ambicionando o melhor resultado. Na camada de saída, os autores utilizaram 236 neurônios. Com a metodologia aplicada, os autores concluíram que o classificador

NB proporcionou um resultado mais satisfatório do que aquele obtido com o uso da RNA.

Em 2008, Tellaeche e colaboradores utilizaram a segmentação baseada em técnicas de *Support Vector Machines* - (SVM) para identificarem as plantas daninhas em plantações de cereais (TELLAECHE et al., 2008). O seu uso promoveu a redução da quantidade de herbicida pulverizada nas áreas estudadas.

Em 2012, Guerrero e colaboradores desenvolveram um método utilizando o classificador SVM para a identificação de componentes espectrais verdes e vermelhos em plantas da cultura do milho (GUERRERO et al., 2012). Os componentes espectrais verdes estão associados à planta do milho, já os componentes vermelhos referem-se aos materiais existentes no solo que se misturam com água e com as palhas presentes em áreas de cultura do milho. A estratégia utilizada pelos autores, consistiu em aplicar o método de Otsu para realizarem a segmentação e a identificação das plantas. Em seguida, foi aplicado SVM para classificar os *pixels* que não foram identificados como plantas da cultura de milho, como o solo, as plantas daninhas e os outros materiais. Dessa maneira, os autores concluíram ser viável o uso desse método para identificação automática de plantas daninhas em áreas de plantação.

Em 2018, Liakos e colaboradores apresentaram uma revisão de pesquisas que utilizaram o Aprendizado de Máquina (*Machine Learning* - ML), em ambientes agrícolas, focando em detecção e no reconhecimento de plantas (LIAKOS et al., 2018). Esses autores trataram de diversos modelos de aprendizado de máquina que se encontram na literatura, dentre eles, aqueles baseados em: Rede Neural Artificial (*Artificial Neural Network*-ANN), Modelo Bayesiano (*Bayesian Models*- BM), Aprendizado Profundo (*Deep Learning*-DL), Redução de Dimensionalidade (*Dimensionality Reduction* - DR), Árvore de Decisão (*Decision Trees* - DT), Aprendizado em Conjunto (*Ensemble Learning* - EL), Modelo Baseado em Instância (*Instance Based Models* - IBM) e Máquina de Vetor de Suporte (*Support Vector Machines* - SVM).

2.8 Considerações Finais

Nesse Capítulo foi apresentado uma revisão da literatura envolvendo os principais trabalhos relacionados às técnicas do Processamento Digital de Imagens. Tal levantamento, possibilitou explorar as oportunidades de pesquisas quanto aos métodos possíveis para a avaliação de características de objetos de interesses agrícolas, como, por exemplo, a oportunidade para a classificação de sementes oleaginosas. Nesses trabalhos, foi possível observar e avaliar os níveis de acuracidade que esses autores encontraram nas diferentes abordagens dos objetos estudados.

Diante desse cenário, para esse trabalho, foi importante observar a necessidade de considerar a avaliação de diferentes filtros para a etapa de pré-processamento de imagens de sementes oleaginosas, assim como a oportunidade no uso dos métodos de Limiarização e HOG para as etapas de segmentação e de extração de características, bem como a avaliação de classificadores baseados em modelos Bayesianos e SVM.

No Capítulo seguinte será abordado o referencial teórico das principais técnicas avaliadas para a organização do método para a classificação de sementes agrícolas em imagens obtidas por TC em alta resolução.

Capítulo 3

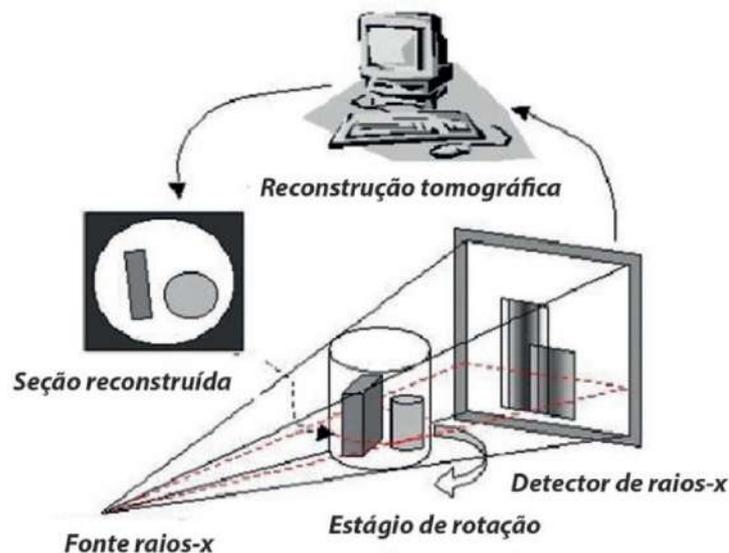
FUNDAMENTAÇÃO TEÓRICA

Este Capítulo apresenta os fundamentos teóricos das técnicas do Processamento de Imagens, da Visão Computacional e da TC que serão utilizados para a formulação do método de classificação de sementes agrícolas oleaginosas. Ademais, será apresentado com maior detalhamento sobre as técnicas de classificação de padrões em imagens digitais e de análise baseada em componentes principais.

3.1 Tomografia Computadorizada

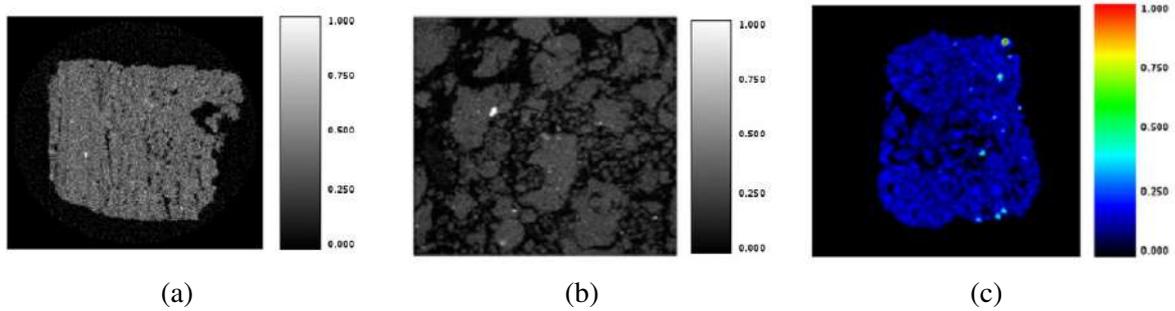
A TC apresenta, como resultado decorrente do processo da reconstrução de projeções tomográficas, uma imagem digital que pode ser bidimensional ou tridimensional. Cada *pixel* ou voxel dessas imagens estão relacionados ao coeficiente de atenuação de massa (cm^2/g) que dependem da energia dos feixes de raios-X ou raios γ utilizados. A Figura 1 ilustra, em diagrama de blocos, a estrutura básica de um tomógrafo utilizando a análise não invasiva e não destrutiva.

Figura 1 – Representação ilustrativa de uma metodologia para a aquisição de imagens tomográficas (Fonte: Adaptado de Hounsfield (1973)).



A Figura 2 ilustra exemplos de imagens tomográficas obtidas em diferentes resoluções espaciais e a energia da fonte de raios-X.

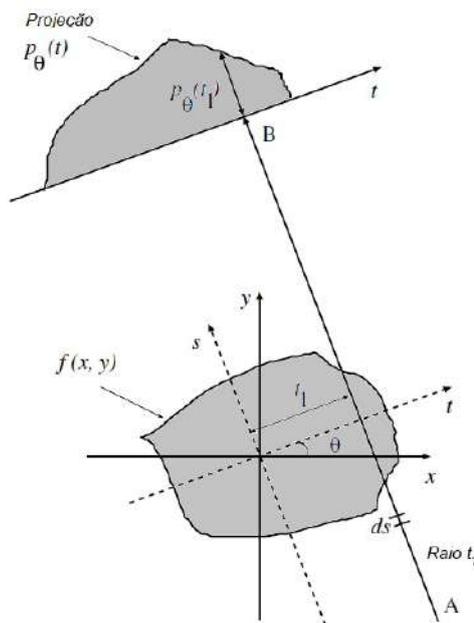
Figura 2 – Exemplos de imagens tomográficas bidimensional (2a e 2b) e tridimensional (2c) do solo agrícola (Fonte: Retirado de Beraldo et al. (2014) e Pereira e Cruvinel (2015))



3.1.1 Reconstrução de imagens tomográficas

O processo aplicado para realizar a aquisição das imagens TC consiste em uma fonte com emissão de feixes de raios-X, que foi emitido em linha reta sobre toda a estrutura do corpo, em diferentes ângulos. Dessa forma, a intensidade emitida pela fonte de raios-X foi captada através de um detector para que se possa ser imageada em um plano cartesiano. Um exemplo desse processo de aquisição de um objeto pode ser ilustrado conforme a Figura 3.

Figura 3 – Transformada de Radon para uma projeção $f(x,y)$ (Fonte: Adaptado de Rangayyan (2004)).



Conforme ilustrado pela Figura 3, a aplicação da transformada de Radon é representada por uma imagem contida nas coordenadas (t, s) que será rotacionada em um ângulo θ , no eixo

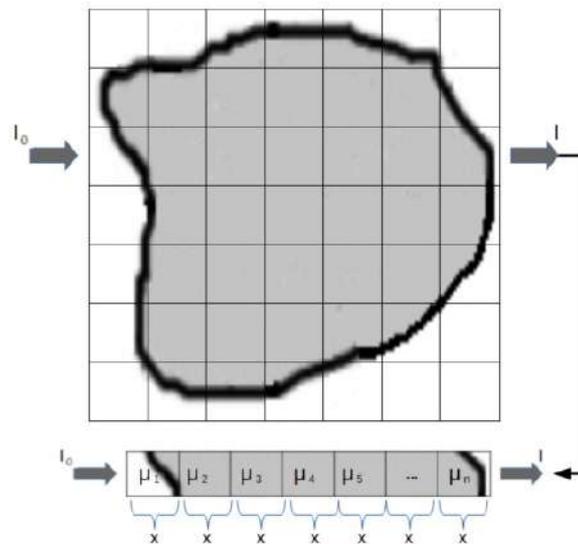
(x, y) . As variáveis $P_{\theta}(t_1)$ assumem os valores obtidos com integral $f(x, y)$, ao longo do raio, e, por fim, temos a projeção $P_{\theta}(t)$ referente à Transformada de Radon (RANGAYYAN, 2004).

A intensidade de emissão dos feixes de raios-X atravessa um objeto causando o efeito de atenuação. Desse modo, matematicamente, esse efeito de atenuação pode ser equacionado utilizando a Lei de *Lambert-Beer*, dada pela equação:

$$I = I_0 e^{-\sum_{i=1}^N \mu_i x_i} \quad (3.1)$$

onde o I representa a intensidade do feixe emergente, o I_0 representa a intensidade do feixe incidente, o μ referente ao coeficiente de atenuação do material e, por fim, a variável x significa a espessura do campo (SEERAM, 2010; SALVADEO, 2013). Desse modo, a medida que o feixe de raios-X passa pelos elementos de um objeto, contido em uma mesma fatia, uma mediação de atenuação foi aplicada a fim de que se obtivesse a soma desses raios. Um exemplo desse processo de atenuação, ao longo de uma fatia de um objeto, foi ilustrado conforme a Figura 4.

Figura 4 – Representação da intensidade do feixe de raios-X sobre uma pilha de *pixels* (Fonte: Adaptado de Seeram (2010)).



No entanto, o sistema de reconstrução de imagens tomográficas foi realizado através da união de um conjunto de projeções unidimensionais, de modo que o seu resultado final foi transformado em uma imagem bidimensional. Para se tratar da reconstrução, primeiramente, se fez necessário atentar-se sobre a transformada de Radon, a qual foi relacionada à decomposição da imagem em projeções. Logo após a aplicação da transformada de Radon, os algoritmos de reconstrução realizaram a transformada inversa de Radon de forma que no final desse processo foi-se obtida uma imagem reconstruída.

3.1.1.1 Transformada de Radon

A transformada de Radon consiste em buscar a reconstrução de uma função $f(x, y)$ a partir de suas projeções $P_\theta(t)$. Sendo assim, com o raio denotado pelo segmento \overline{AB} , conforme apresentado na Figura 3, foi possível escrever:

$$x \cdot \cos \theta + y \cdot \sin \theta = t_1 \tag{3.2}$$

onde t_1 representa a distância do raio até a linha s e a θ o ângulo de orientação. Sendo assim, a equação descrita pelo raio \overline{AB} é representada pela integral $P_\theta(t)$ dada por:

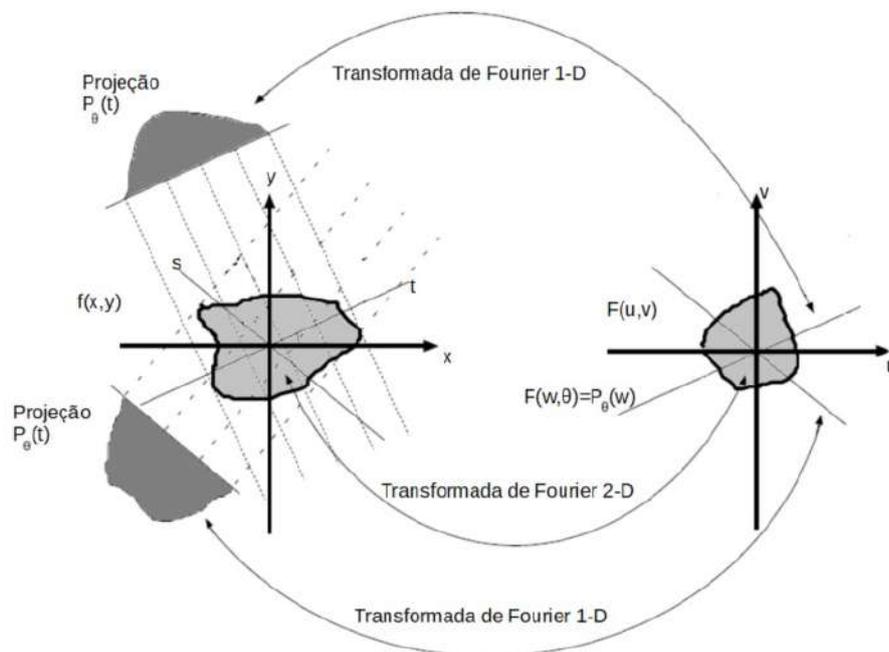
$$P_\theta(t_1) = \int_{AB} f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(x \cos \theta + y \sin \theta - t_1) dx dy. \tag{3.3}$$

onde a função $\delta(\cdot)$ representa a função delta de Dirac.

3.1.1.2 Teorema das Secções de Fourier

O processo de reconstrução tomográfica de uma imagem consiste em reconstruir uma função bidimensional $f(x, y)$, a partir de um conjunto de projeções tomográficas unidimensionais adquiridas pela transformada de Radon. Nesse contexto, foi utilizado o conceito matemático do Teorema das Secções de Fourier para a reconstrução de imagens. O Teorema das Secções de Fourier determina que a transformada de Fourier 1-D, de uma projeção paralela, referente a uma imagem bidimensional obtida em um ângulo θ , foi equivalente a uma fatia da transformada de Fourier 2-D de um objeto, assim como mostra a Figura 5.

Figura 5 – Teorema do corte de Fourier (Fonte: Adaptado de Rangayyan (2004)).



A ilustração do Teorema das Secções de Fourier, da Figura 5, realizou a transformada inversa de Fourier, a fim de transformar as coordenadas polares em coordenadas cartesianas.

De acordo com Rangayyan (2004), o desenvolvimento matemático do Teorema das Secções de Fourier foi representado através da forma $F(u, v)$. Considerando a transformada de Fourier de uma função $f(x, y)$, definimos por:

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j2\pi(ux+vy)} dx dy. \quad (3.4)$$

e sua transformada inversa como:

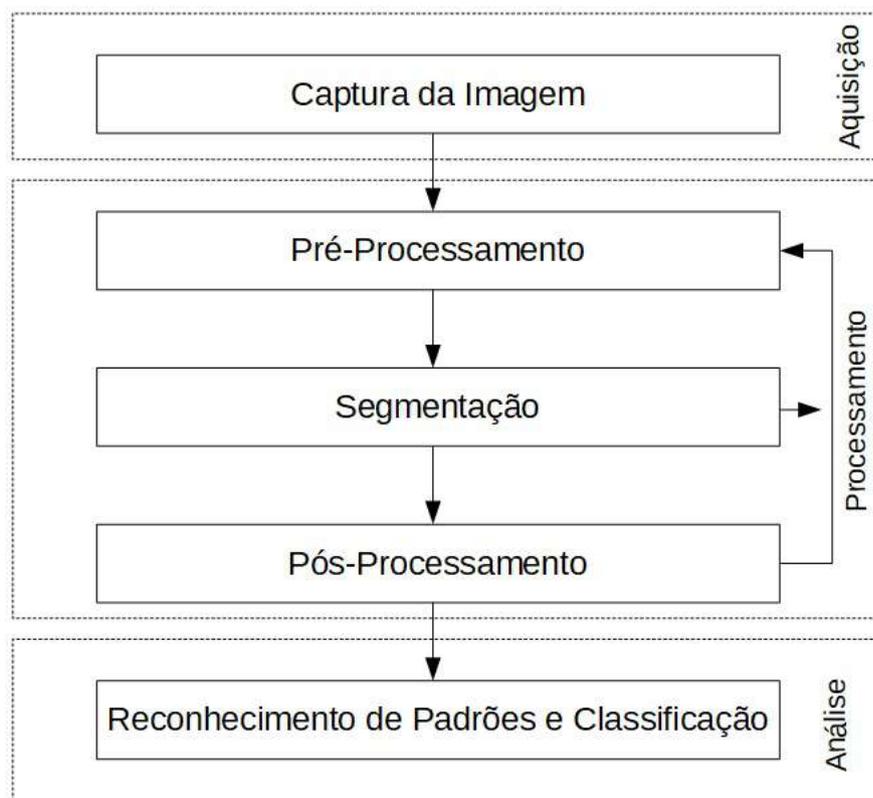
$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) e^{j2\pi(ux+vy)} dudv. \quad (3.5)$$

No final da transformada inversa de Fourier, o resultado obtido foi em coordenadas polares, sendo, contudo, necessário converter para coordenadas cartesianas (SALINA, 2007).

3.2 Processamento de Imagens

Segundo Gonzalez e Woods, as fases do processamento de imagens são compostas pelas etapas que foram ilustradas no diagrama de blocos na Figura 6 (GONZALEZ; WOODS, 2007).

Figura 6 – Diagrama de blocos das etapas do processamento de imagens (Fonte: Adaptado de Gonzalez e Woods (2007))



Essas fases envolveram os elementos de captura da imagem até o reconhecimento de padrões e de classificação. Em outras aplicações, essas etapas podem ser reestruturadas para se adaptarem às necessidades dos problemas a serem tratados.

3.2.1 Conceito de imagem digital

Uma imagem digital pode ser descrita matematicamente por uma função bidimensional $f(x, y)$, tornando f correspondente à intensidade luminosa ou ao nível de cinza das coordenadas espaciais (x, y) . A imagem $f(x, y)$ foi arranjada na forma de uma matriz $M \times N$ descrita conforme apresentada na Equação 3.6, enquanto que cada elemento foi conhecido como *pixel* e armazenado em uma posição corresponde ao valor de intensidade daquela coordenada.

$$f(x, y) \approx \begin{bmatrix} f(0, 0) & f(0, 1) & \cdots & f(0, M - 1) \\ f(1, 0) & f(1, 1) & \cdots & f(1, M - 1) \\ \vdots & \vdots & \ddots & \vdots \\ f(N - 1, 0) & f(N - 1, 1) & \cdots & f(N - 1, M - 1) \end{bmatrix} \quad (3.6)$$

Uma propriedade importante da representação matricial de uma imagem foi a vizinhança. A vizinhança se caracterizou por uma operação local para determinar se o *pixel* p e os seus vizinhos fizeram parte ou não do objeto. A representação de vizinhança foi dada por:

- Vizinhança-4: representou para determinado *pixel* p de uma imagem, com coordenadas (x, y) , que existiram quatro vizinhos formados pelos *pixels* que faziam fronteira com p nos eixos verticais e horizontais. Sua representação foi expressa por:

$$(x + 1, y), (x - 1, y), (x, y + 1) \text{ e } (x, y - 1) \quad (3.7)$$

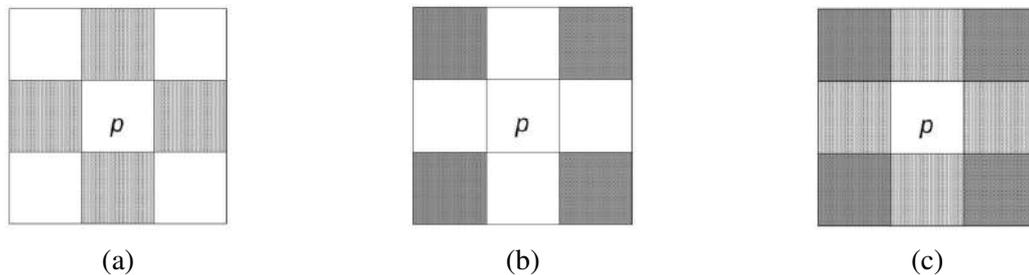
- Vizinhança diagonal: representou para determinado *pixel* p de uma imagem, com coordenadas (x, y) , que existiram quatro vizinhos formados pelas diagonais primária e secundária. Sua representação foi expressa por:

$$(x + 1, y + 1), (x - 1, y - 1), (x - 1, y + 1) \text{ e } (x + 1, y - 1) \quad (3.8)$$

- Vizinhança-8: representou para determinado *pixel* p de uma imagem, com coordenadas (x, y) , que sua estrutura foi formada pela união dos *pixels* da vizinhança-4 e da diagonal.

Foi possível representar de forma ilustrativa as três vizinhanças do *pixel* p , tendo como base a ilustração representada pela Figura 7.

Figura 7 – Representação ilustrativa do conceito de vizinhança do *pixel*, sendo vizinhança-4 (7a), vizinhança diagonal (7b) e vizinhança-8 (7c) (Fonte: Adaptado de Filho e Neto (1999)).



3.2.2 Pré-Processamento

A etapa do Pré-Processamento de imagens, ou também conhecida por "Processamento de Baixo Nível", é o processo a ser realizado para a redução de degradações nas imagens, assim como é possível nas técnicas de suavização, de detecção de bordas e de realce. A etapa de pré-processamento visa o aprimoramento da qualidade da imagem para o seu uso nas etapas subsequentes.

3.2.2.1 Ruído em Imagens

Na área do processamento de imagens, os fatores que causam a geração de ruído em imagens digitais podem surgir durante o processo de aquisição, de gravação, de processamento e de transmissão de imagens (AMER; DUBOIS, 2005). No processo de aquisição, existem os fatores que afetam a qualidade da imagem devido às condições ambientais durante o processo ou à qualidade dos sensores utilizados para a sua captação. Quando ocorre uma transmissão dessa imagem, a mesma ainda pode ser afetada devido às possíveis interferências que ocorrem durante a sua transmissão.

O modelo matemático utilizado para descrever o processo de degradação de uma imagem digital, pelo borramento e a presença de ruído no domínio espacial, pode ser dado por:

$$f'(x, y) = f(x, y) * h(x, y) + \zeta(x, y) \quad (3.9)$$

onde $f'(x, y)$ foi o resultado da imagem degradada após sua aquisição, $h(x, y)$ foi associado à adição de ruído dado por $\zeta(x, y)$ e $*$ foi a operação de convolução.

O conceito de ruído é considerado como uma variação aleatória de informações das intensidades de uma imagem, o qual é caracterizado por uma função de densidade de probabilidade (FDP). Nesse contexto, as principais funções encontradas na área do processamento de imagens são: o ruído impulsivo, o ruído Gaussiano, entre outros (SILVA et al., 2017).

O ruído impulsivo, também conhecido como ruído Sal e Pimenta, apresenta características sobre a intensidade dos *pixels* degradados de uma imagem digital. Dessa maneira, os *pixels*

degradados são modificados de forma aleatória ocasionando sobre a imagem pontos pretos e brancos (WANG; ZHANG, 1999). Sua representação matemática foi dada por:

$$p(z) = \begin{cases} P_a & \text{para } z = a; \\ P_b & \text{para } z = b; \\ 0 & \text{caso contrario.} \end{cases} \quad (3.10)$$

se $b > a$ significa a intensidade, b será representada na imagem como um ponto branco e a intensidade a como um ponto preto.

O ruído Gaussiano, que pode também assumir a característica de um ruído de distribuição normal, é o modelo utilizado com a maior frequência na avaliação do processo de degradação de uma imagem digital, pois possibilita variações em seus parâmetros tanto no domínio espacial quanto no domínio da frequência. Sua equação foi expressa por:

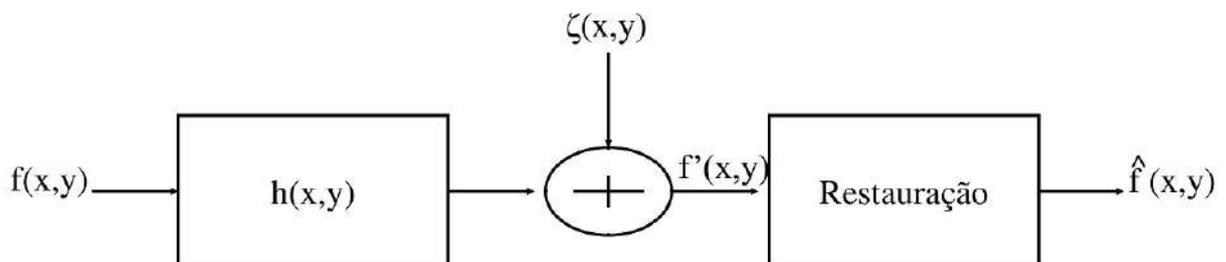
$$p(z) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(z-\bar{z})^2}{2\sigma^2}} \quad (3.11)$$

onde z representa a intensidade em escala de cinza, \bar{z} a média dos valores de z e σ o desvio padrão do ruído.

3.2.2.2 Filtragem

As técnicas de filtragem são compostas por operações envolvendo os *pixels* da imagem determinando o valor do *pixel* central e de todos os seus vizinhos. Tais operações baseiam-se em métodos que proporcionam a redução de ruídos, a suavização e o realce da imagem. Tipicamente, são utilizados os filtros passa-alta, o passa-baixa e o passa-faixa, os quais auxiliam na melhoria da relação Sinal/Ruído, assim como também podem ressaltar as informações como as bordas, os contornos, entre outros. A Figura 8 ilustra, em diagrama de blocos, as etapas envolvidas na composição do sinal com ruído aditivo e a etapa de filtragem.

Figura 8 – Diagrama de blocos da etapa de filtragem da imagem (Fonte: Adaptado de Banham e Katsaggelos (1997)).



3.2.2.2.1 Filtro no Domínio Espacial

As técnicas de filtragem, no domínio espacial, realizam a aplicação de filtros diretamente sobre a matriz de *pixels* da imagem, por meio de operações envolvendo a convolução entre

a imagem e uma máscara ou o *kernel* do filtro considerado. Assim, a função de filtragem de imagens no domínio espacial pode ser expressa por:

$$\hat{f}(x, y) = T[f'(x, y)] \tag{3.12}$$

onde $\hat{f}(x, y)$ é o resultado da imagem processada, $f'(x, y)$ refere-se à imagem degradada e T é o operador que promove a filtragem.

Filtro de Média

Considerado um filtro passa-baixa linear de suavização, o filtro de média destaca-se por sua capacidade de reduzir as variações de níveis de cinza entre os *pixels* adjacentes diminuindo o ruído e suavizando o contraste (EUSTÁQUIO et al., 2001; MENESES et al., 2012). Foi representado por:

$$\hat{f}(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f'(x - s, y - t) \tag{3.13}$$

onde:

$$a = (M - 1)/2 \tag{3.14}$$

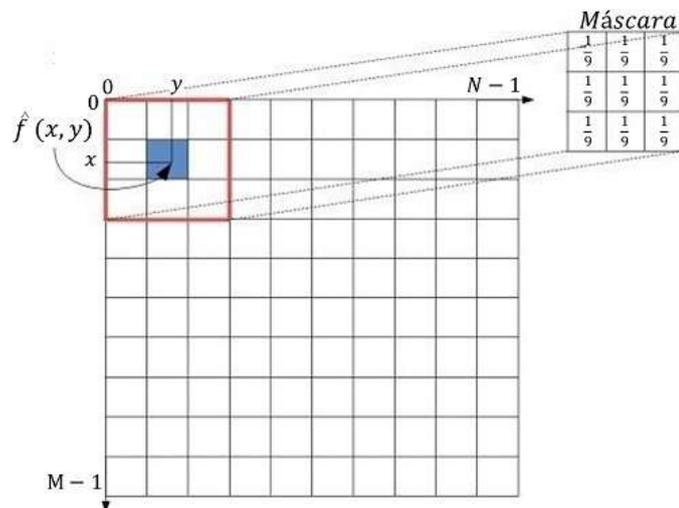
e

$$b = (N - 1)/2 \tag{3.15}$$

sendo que $\hat{f}(x, y)$ representa o resultado da imagem processada, $M \times N$ o tamanho da imagem de referência e $w(s, t)$ evidência a máscara (ou *kernel*) de dimensão quadrada de tamanho K , de forma que é definido multiplicado por $(\frac{1}{K})$.

Conforme a Figura 9, o filtro de média foi executado a cada iteração através da multiplicação da máscara de filtragem com os *pixels* da imagem de referência. O valor resultante dessa filtragem foi atribuído ao *pixel* central da imagem sob a janela (FILHO; NETO, 1999).

Figura 9 – Diagrama esquemático do processo do filtro de média utilizando uma máscara 3x3 (Fonte: Adaptado de GONZALEZ e WOODS (1992)).



Filtro Gaussiano

O filtro Gaussiano é um método que viabiliza a suavização de uma imagem, sendo muito utilizado na área do processamento de imagens e de visão computacional. A aplicação desse filtro reduz o ruído de forma ponderada e simétrica (WELLS, 1986; DENG; CAHILL, 1994; HSIAO et al., 2007; MATEI, 2013). Sua aplicação envolveu uma convolução da imagem degradada $f'(x, y)$ com uma função Gaussiana $G(x, y)$, na forma:

$$\hat{f}(x, y) = f'(x, y) * G(x, y) \quad (3.16)$$

O modelo matemático do núcleo (*kernel*) Gaussiano de uma função bidimensional foi representado por:

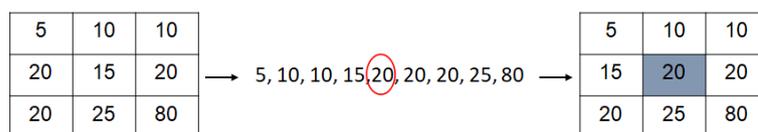
$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (3.17)$$

onde as variáveis x e y representaram as coordenadas cartesianas da máscara, no eixo horizontal e vertical, mostrando as dimensões da janela, respectivamente. A variável σ , representou o desvio padrão da distribuição Gaussiana dos *pixels*, onde $\sigma > 0$.

Filtro da Mediana

Análogo ao filtro da média, o filtro da mediana é categorizado como filtro passa-baixa não linear. Esse filtro se destaca por possuir características de suavização que levam à redução de ruídos preservando as bordas e outros detalhes da imagem (GONZALEZ; WOODS, 2007). Isso deve-se ao fato de que, para a realização da filtragem por mediana, os valores dos níveis de cinza dos *pixels* da vizinhança são ordenados. Seu desempenho é eficiente em situações em que a imagem apresenta um ruído impulsivo. A Figura 10 ilustra o filtro da mediana onde, assim como o exemplo, o conjunto de valores (5, 10, 10, 20, 15, 20, 20, 25, 80) são ordenados e apresentados na forma (5, 10, 10, 15, 20, 20, 20, 25, 80), sendo a mediana o 5º maior elemento, ou seja, igual 20.

Figura 10 – Diagrama esquemático do processo do filtro da mediana utilizando uma matriz de convolução com dimensão 3x3, onde $K = 1$.



Filtro Non-local Means

O método de filtragem *Non-Local Means* (NLM) foi proposto no ano de 2005, por Buades, Coll e Morel, como uma técnica aplicada para lidar com a redução de ruído aditivo do tipo gaussiano em imagens (BUADES et al., 2005). Nesse contexto, o algoritmo proposto pelo método NLM baseia-se no fato de que as imagens naturais possuem características que

se repetem não somente nos locais, mas também de maneira global na imagem. Sendo assim, o processo realizado pelo método em questão busca o valor estimado da intensidade de cada *pixel* da imagem aplicando o cálculo da média ponderada em uma certa região similar contida na imagem. Desse modo, a similaridade foi estimada conforme uma imagem discreta com ruído $f' = f'(i)|i \in f$, $NLM [f'] (i)$, onde o NLM representou o valor estimado para um *pixel* i , determinada pela equação:

$$NLM [f'] (i) = \sum_{j \in f} w(i, j) f'(j) \quad (3.18)$$

onde $w(i, j)$ representa os pesos atribuídos à similaridade entre os *pixels* i e j , satisfazendo a condição $0 \leq w(i, j) \leq 1$ e $\sum_j w(i, j) = 1$. A similaridade entre os *pixels* i e j tem como analogia a semelhança dos vetores de intensidades nos níveis de cinza $f'(N_i)$ e $f'(N_j)$, respectivamente (BUADES et al., 2005). Logo, a equação 3.19 foi utilizada para o cálculo do peso $w(i, j)$, na forma:

$$w(i, j) = \frac{1}{Z(i)} e^{-\frac{\|f'(N_i) - f'(N_j)\|_{2,\tau}^2}{\sigma^2}} \quad (3.19)$$

onde o valor de $\tau > 1$, a constante $Z(i)$ refere-se a uma função de normalização e σ o desvio padrão do ruído gaussiano na imagem expressos pela equação 3.20.

$$Z(i) = \sum_j e^{-\frac{\|f'(N_i) - f'(N_j)\|_{2,\tau}^2}{\sigma^2}} \quad (3.20)$$

Dessa forma, o método de filtragem NLM permite comparar o nível de cinza com toda a configuração geométrica de uma vizinhança inteira, mostrando o potencial para encontrar as amostras em toda a imagem (BUADES et al., 2005; BUADES et al., 2010).

Filtro de Difusão Anisotrópica

O filtro de Difusão Anisotrópica foi proposto no ano de 1990 por Perona e Malik (PERONA; MALIK, 1990). Esse filtro é um método adaptativo e não linear que visa a redução de ruídos, a suavização intra-região e a preservação de borda da imagem (ARGENTI et al., 2013). Sua implementação levou em consideração a convolução de uma imagem degradada $f'(x, y)$, com uma função Gaussiana $G(x, y; t)$, em um intervalo de tempo t , conforme a equação:

$$\hat{f}(x, y; t) = f'(x, y) * G(x, y; t) \quad (3.21)$$

sendo o filtro Gaussiano representado por:

$$G(x, y; t) = \frac{1}{2\pi t} e^{-(x^2+y^2)/2t} \quad (3.22)$$

Baseando-se em Equações Diferenciais Parciais (EDP), Perona e Malik envolveram a discretização da equação não linear de difusão anisotrópica, que pode ser representada por:

$$\hat{f}_t = \text{div}(c(x, y, t)\nabla \hat{f}) = c(x, y, t)\Delta \hat{f} + \nabla c \cdot \nabla \hat{f} \quad (3.23)$$

em que div representa o operador de Divergente, os operadores Δ e ∇ indicam respectivamente os operadores Laplaciano e Gradiente. No entanto, a equação 3.23 se reduz para equação de difusão isotrópica de calor $\hat{f}_t = c \cdot \Delta \hat{f}$, se $c(x, y; t)$ for uma constante.

Segundo Perona e colaboradores, a equação 3.23 pode ser discretizada em uma rede com vizinhança-4, como ilustrado pela Figura 11 (PERONA et al., 1994), representando os valores de brilho (*pixels*) associados aos vértices e os coeficientes de condução aos arcos.

Essa estrutura de discretização, mais próxima do operador Laplaciano, pode ser escrita como:

$$\hat{f}_{i,j}^{t+1} = \hat{f}_{i,j}^t + \lambda \left[c_N \cdot \nabla_N \hat{f} + c_S \cdot \nabla_S \hat{f} + c_E \cdot \nabla_E \hat{f} + c_W \cdot \nabla_W \hat{f} \right]_{i,j}^t \quad (3.24)$$

onde i, j representam a intensidade do *pixel* (i,j) na imagem, $0 \leq \lambda \leq \frac{1}{4}$ pertence ao parâmetro de velocidade da difusão, as siglas N, S, E e W representam as regiões Norte, Sul, Leste e Oeste da imagem, $\nabla_N \hat{f}_{i,j}$, $\nabla_S \hat{f}_{i,j}$, $\nabla_E \hat{f}_{i,j}$ e $\nabla_W \hat{f}_{i,j}$ indicam as diferenças dos vizinhos mais próximos entre a intensidade dos *pixels* (i,j) , sendo dadas por:

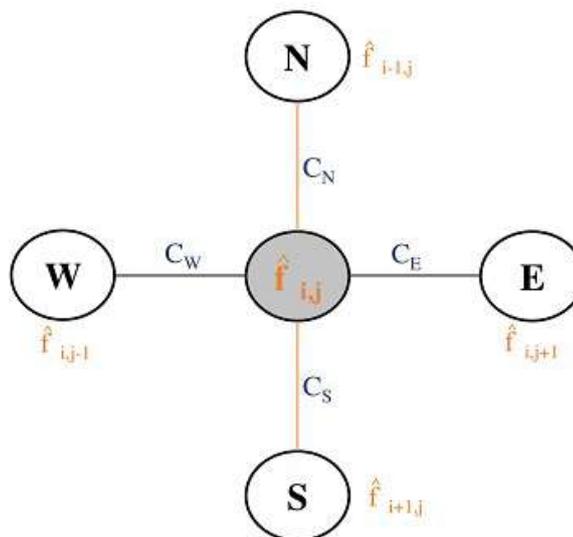
$$\nabla_N \hat{f}_{i,j}^t = \hat{f}_{i-1,j} - \hat{f}_{i,j} \quad (3.25)$$

$$\nabla_S \hat{f}_{i,j}^t = \hat{f}_{i+1,j} - \hat{f}_{i,j} \quad (3.26)$$

$$\nabla_E \hat{f}_{i,j}^t = \hat{f}_{i,j+1} - \hat{f}_{i,j} \quad (3.27)$$

$$\nabla_W \hat{f}_{i,j}^t = \hat{f}_{i,j-1} - \hat{f}_{i,j} \quad (3.28)$$

Figura 11 – Estrutura computacional esquemática para o algoritmo do método de Difusão Anisotrópica (Fonte: Adaptado de Perona et al. (1994)).



Ademais, uma função c^t foi criada para calcular o valor do gradiente em todas as direções das regiões. Desse modo, foi utilizado o valor absoluto da norma do gradiente local $\nabla_N \hat{f}_{i,j}$, $\nabla_S \hat{f}_{i,j}$, $\nabla_W \hat{f}_{i,j}$ e $\nabla_E \hat{f}_{i,j}$ em cada região do arco (PERONA; MALIK, 1990; SOUZA et al., 2016). Essas equações são descritas como:

$$c_{N_{i,j}}^t = g \left(\left| \nabla_N \hat{f}_{i,j}^t \right| \right) \quad (3.29)$$

$$c_{S_{i,j}}^t = g \left(\left| \nabla_S \hat{f}_{i,j}^t \right| \right) \quad (3.30)$$

$$c_{E_{i,j}}^t = g \left(\left| \nabla_E \hat{f}_{i,j}^t \right| \right) \quad (3.31)$$

$$c_{W_{i,j}}^t = g \left(\left| \nabla_W \hat{f}_{i,j}^t \right| \right) \quad (3.32)$$

Também, Perona e Malik (1990) apresentaram uma proposta para o cálculo do filtro função de g definida da seguinte forma:

$$g \left(\nabla \hat{f} \right) = e^{-(\|\nabla \hat{f}\|/\kappa)^2} \quad (3.33)$$

e

$$g \left(\nabla \hat{f} \right) = \frac{1}{1 + \left(\frac{\|\nabla \hat{f}\|}{\kappa} \right)^2} \quad (3.34)$$

sendo κ uma variável responsável para calcular a condutividade da difusão.

3.2.2.2.2 Filtros no Domínio da Frequência

Considerado um outro tipo de categoria de filtragem, os filtros no domínio da frequência têm a sua base matemática fundamentada no teorema da convolução, conforme foi aplicado no domínio espacial (FILHO; NETO, 1999; GONZALEZ; WOODS, 2007). Entretanto, foram estabelecidas essas operações no domínio da frequência. Então, a filtragem no domínio da frequência de uma função bidimensional envolveu o procedimento da transformada de Fourier da imagem degradada $f'(x,y)$. Logo, $\hat{F}(u,v)$ foi o resultado da convolução que passou a ser representado pela multiplicação de $F'(u,v)$, que demonstrou a transformada da imagem de referência, multiplicado por um filtro $W(u,v)$, conforme foi apresentado na equação 3.35.

$$\hat{F}(u,v) = F'(u,v) \cdot W(u,v) \quad (3.35)$$

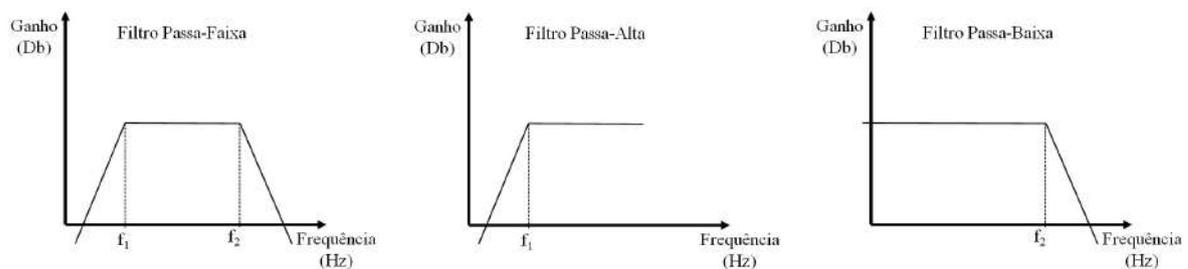
Nesse contexto, para a aplicação do filtro no domínio da frequência de uma imagem, deve-se primeiramente aplicar a transformada discreta de Fourier (DFT - *Discrete Fourier*

Transform), obtendo a transformada inversa como resultado da imagem restaurada no domínio espacial, ou seja:

$$\hat{f}(x, y) = \mathfrak{S}^{-1}[F'(u, v) \cdot W(u, v)] \quad (3.36)$$

Dentro do processo de filtragem, no domínio da frequência, destacam-se os filtros passa-baixa, o passa-alta e o passa-faixa em que suas abordagens foram aplicados em diferentes situações, o que levou à variação da magnitude do sinal bidimensional resultante. A Figura 12 ilustra diagramas de ganhos em função da frequência para a aplicação da filtragem passa-baixa, passa-alta e passa-faixa, respectivamente.

Figura 12 – Diagrama de ganhos versus frequência para os filtros passa-faixa, o passa-alta e o passa-baixa (Fonte: Adaptado de Oppenheim et al. (1998)).



3.2.3 Segmentação

A etapa de segmentação de imagens é uma tarefa que se refere à decomposição da imagem em várias regiões (JAIN, 1989). Entretanto, voltado para o processamento digital de imagens, essa decomposição é peculiar em relação ao problema a ser resolvido, ou seja, seu término acontece quando o objeto de interesse estiver isolado na imagem (GONZALEZ; WOODS, 2007).

O processo de segmentação, de forma geral, é considerado uma das etapas mais trabalhosas da área do processamento de imagem, pois ele é responsável pelo sucesso ou fracasso na etapa de reconhecimento de padrões (GONZALEZ; WOODS, 2007). Já no trabalho de Pal e Pal (1993), os mesmos descreveram a segmentação como uma tarefa complexa pelo fato de ser um problema de percepção psicofísica, onde qualquer tipo de algoritmo de segmentação deve ser aperfeiçoado por meio de heurísticas envolvendo informações semânticas e um conhecimento *a priori* sobre as imagens.

Atualmente, as técnicas de segmentação baseiam-se em propriedades que visam a cor, a textura, a forma, entre outras. Elas são vistas na literatura como técnicas fundamentadas em: segmentação por meio do método Otsu (OTSU, 1979), clusterização (LLOYD, 1982), detecção de bordas (CANNY, 1986; GONZALEZ; WOODS, 2007), watershed (BEUCHER; MEYER, 1993), crescimento de regiões (ZHU; YUILLE, 1996), teoria de grafos (GRADY, 2006; SOUZA et al., 2016), limiarização (GONZALEZ; WOODS, 2007), entre outras. Vale ressaltar, que não há

uma técnica que seja considerada aplicável para todas as imagens e nem para um tipo particular de imagem, sendo assim as soluções são adaptativas aos problemas a serem resolvidos (PAL; PAL, 1993).

3.2.3.1 Método de Limiarização

O método de limiarização é considerado uma das abordagens mais importantes e simples de segmentação (COSTA; CESAR JR., 2000; GONZALEZ; WOODS, 2007). Ele também é conhecido como *thresholding* e tem como fundamento o conceito em bipartição onde são separadas regiões da imagem em duas classes, sendo elas o objeto e o fundo (FILHO; NETO, 1999).

A limiarização geralmente é aplicada quando se trata de objetos com intensidades homogêneas sobre um fundo escuro, ou seja, os *pixels* presentes no objeto e ao fundo têm intensidade em níveis de cinza agrupados em duas classes (PITAS, 2000). Nesse contexto, a segmentação consiste em particionar o histograma da imagem através da seleção de um limiar S , separando o objeto na forma de:

$$\hat{f}_s(x, y) = \begin{cases} 1, & \text{se } f(x, y) > S \\ 0, & \text{se } f(x, y) \leq S. \end{cases} \quad (3.37)$$

onde $\hat{f}_s(x, y)$ é a imagem limiarizada, $f(x, y)$ corresponde à imagem de referência e S ao valor do limiar. Os *pixels* rotulados com valor 1 são do objeto e os *pixels* rotulados com valor 0 são do fundo da imagem.

3.2.3.2 Método de Otsu

Considerado um método de análise de discriminante, não paramétrico e não supervisionado, o método de Otsu seleciona automaticamente um limiar em um histograma de L níveis de cinza, de modo que é possível promover a separação das classes (OTSU, 1979).

Tendo como base uma imagem com L níveis de intensidade, L variando de $[1, 2, \dots, L]$, o número de *pixels* nível i é representado por ψ_i , N é o número de *pixels* totais e p_i denota a frequência de *pixels* com nível de cinza i , sendo possível realizar a normalização da imagem em níveis de cinza conforme a distribuição de probabilidades, dado por:

$$p_i = \frac{\psi_i}{N}, \quad (3.38)$$

para $p_i \geq 0$ e $\sum_{i=1}^L p_i = 1$.

A operação, dada pelo limiar k , divide os L níveis de cinza em duas classes, C_0 e C_1 , representando o objeto e o fundo. A divisão das classes é denotada por $C_0 = 0, 1, \dots, k$ e $C_1 =$

$k+1, k+2, \dots, L$, sendo as probabilidades de ocorrências das classes dadas pelas Equações 3.39 e 3.40, respectivamente:

$$\omega_0 = Pr(C_0) = \sum_{i=1}^k p_i = \omega(k) \quad (3.39)$$

$$\omega_1 = Pr(C_1) = \sum_{i=k+1}^L p_i = 1 - \omega(k) \quad (3.40)$$

A média das classes são expressas pelas Equações 3.41 e 3.42:

$$\nu_0 = \sum_{i=1}^k i Pr(i|C_0) = \sum_{i=1}^k \frac{ip_i}{\omega_0} = \frac{\nu(k)}{\omega(k)} \quad (3.41)$$

$$\nu_1 = \sum_{i=k+1}^L i Pr(i|C_1) = \sum_{i=k+1}^L \frac{ip_i}{\omega_1} = \frac{\nu_L - \mu(k)}{1 - \omega(k)} \quad (3.42)$$

onde:

$$\omega(k) = \sum_{i=1}^k p_i \quad (3.43)$$

e

$$\nu(k) = \sum_{i=1}^k ip_i \quad (3.44)$$

representando os momentos cumulativos de zero e de primeira ordem do histograma de níveis de cinza. Ainda, ν_T refere-se à média total dos níveis de cinza dado por:

$$\nu_T = \nu(L) = \sum_{i=1}^L ip_i \quad (3.45)$$

Segundo Otsu é possível verificar relações que favorecem na escolha de qualquer k , conforme as Equações 3.46 e 3.47, respectivamente:

$$\omega_0 \nu_0 + \omega_1 \nu_1 = \nu_T \quad (3.46)$$

e

$$\omega_0 + \omega_1 = 1 \quad (3.47)$$

As Equações 3.48 e 3.49 definem as devidas variâncias das classes φ_0^2 e φ_1^2 .

$$\varphi_0^2 = \sum_{i=1}^k (i - \nu_0)^2 Pr(i|C_0) = \sum_{i=1}^k (i - \nu_0)^2 \frac{p_i}{\omega_0} \quad (3.48)$$

$$\varphi_1^2 = \sum_{i=k+1}^L (i - \nu_1)^2 Pr(i|C_1) = \sum_{i=k+1}^L (i - \nu_1)^2 \frac{p_i}{\omega_1} \quad (3.49)$$

Assumindo a φ_W^2 como variância dentro da classe, a φ_B^2 como a variância entre a classe e a φ_T^2 como a variância total foi possível encontrar um limiar ótimo pela minimização de uma das funções discriminantes abaixo, ou seja:

$$\lambda = \frac{\varphi_B^2}{\varphi_W^2}, \quad \vartheta = \frac{\varphi_B^2}{\varphi_T^2}, \quad \kappa = \frac{\varphi_T^2}{\varphi_W^2} \quad (3.50)$$

onde:

$$\varphi_W^2 = \omega_0 \varphi_0^2 + \omega_1 \varphi_1^2 \quad (3.51)$$

$$\varphi_B^2 = \omega_0 \omega_1 (\nu_1 - \nu_0)^2 \quad (3.52)$$

$$\varphi_T^2 = \sum_{i=1}^L (i - \nu_T)^2 p_i \quad (3.53)$$

Observa-se que as funções φ_W^2 e φ_B^2 dependem do limiar k , enquanto que a φ_T^2 não depende do limiar. Além disso, foi possível observar que a φ_B^2 é uma estatística de primeira ordem e φ_W^2 foi apresentada como um estatística segunda ordem, o que diferiu a φ_W^2 foi o fato da variância dentro da classe. Entretanto, dentre as três funções da Equação 3.50, a função ϑ foi considerada a mais simples entre as outras, portanto, ela foi adotada como critério de avaliação para a separabilidade de limiar no nível k (OTSU, 1979).

O limiar para k^* (limiar ótimo), que maximiza a função ϑ ou que, equivalentemente, maximiza a função φ_B^2 , foi selecionada conforme a pesquisa sequencial dada pelas Equações 3.43 e 3.44. Também na opção de forma explícita através das Equações 3.39 até 3.42, dado que:

$$\vartheta(k) = \frac{\varphi_B^2(k)}{\varphi_T^2} \quad (3.54)$$

$$\varphi_B^2(k) = \frac{[\nu_T \omega(k) - \nu(k)]^2}{\omega(k)[1 - \omega(k)]} \quad (3.55)$$

sendo o limiar ótimo (k^*) definido pela Equação 3.56:

$$\varphi_B^2(k^*) = \max_{1 \leq k \leq L} \{ \varphi_B^2(k) \} \quad (3.56)$$

O método de Otsu é um processo simples que utiliza somente os momentos cumulativos zero e de primeira ordem do histograma.

3.2.3.3 Método de Corte em Grafo

A Teoria dos Grafos teve os seus primeiros trabalhos, no ano de 1736, desenvolvidos pelo matemático e físico Leonhard Euler que propôs solucionar o problema das Sete Pontes de

Königsberg utilizando o grafo (LLOYD et al., 1978). Daí por diante, inúmeros trabalhos vêm sendo difundidos considerando a teoria dos grafos para solucionar problemas em diversas áreas.

Um grafo é considerado um conjunto finito $G = (V, A)$ cujos elementos V são chamados de vértices e os elementos A são chamado de arestas, respectivamente. Cada aresta de A é formada por um conjunto de pares de vértices $a = v_i, v_j$, tal que v_i e $v_j \in V$. Caso dois vértices estejam conectados por uma única aresta, elas são chamadas de adjacentes ou vizinhos (FEOFILOFF et al., 2009). Para cada aresta associa-se um valor numérico (peso) que varia de acordo com a propriedade do problema, por exemplo, a diferença de intensidade entre os dois vértices.

Atualmente, pesquisas na área do processamento de imagens vêm utilizando a teoria dos grafos como estrutura matemática para ser aplicada como técnica para a segmentação de imagens. Nessa abordagem, a representação estrutural da imagem é feita no formato de grafo, sendo que cada posição (*pixel*) da imagem se refere ao vértice do grafo e as arestas são estabelecidas a partir das relações entre eles.

No entanto, para a segmentação de uma imagem, se baseando nos conceitos da Teoria dos Grafos, deve se realizar inicialmente o particionamento (corte) de um certo grafo ponderado originando assim dois subgrafos (SHI; MALIK, 2000). Logo, cada subgrafo contém um conjunto de vértices que são pertencentes ao objeto de interesse ou ao fundo da imagem.

Os primeiros trabalhos que utilizaram o conceito da teoria dos grafos aplicados no processamento de imagens foram realizados por Greig e colaboradores, os quais propuseram um algoritmo de fluxo máximo em grafo para minimizarem as funções de energia (GREIG et al., 1989). Nesse contexto, os algoritmos de fluxo máximo tradicionais, como por exemplo o Ford-Fulkerson, foram aplicados em um grafo para a classificação dos *pixels* de uma imagem em diferentes regiões, sendo eles representados pelos cálculos de energia mínima (BOYKOV; JOLLY, 2001). Nesse caso, o cálculo da função de energia para realizar a segmentação da imagem foi representado pela equação:

$$E(A) = \lambda \cdot R(A) + B(A) \quad (3.57)$$

onde o coeficiente $\lambda \geq 0$ é

$$R(A) = \sum_{p \in P} R_p(A_p) \quad (3.58)$$

$$B(A) = \sum_{\{p,q\} \in P} B_{\{p,q\}} \cdot \delta(A_p, A_q) \quad (3.59)$$

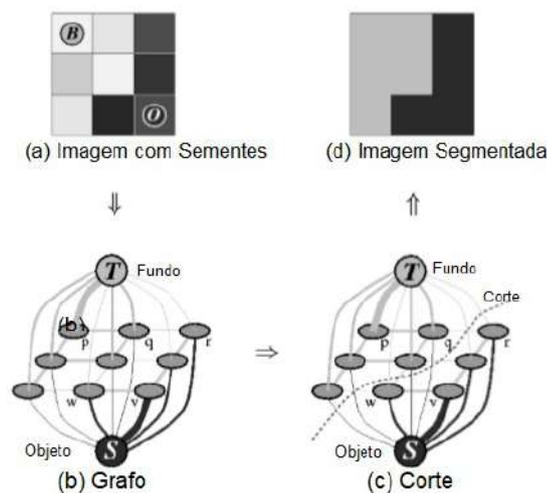
$$\delta(A_p, A_q) = \begin{cases} 1 & \text{if } A_p \neq A_q \\ 0 & \text{otherwise} \end{cases} \quad (3.60)$$

A função $R(A)$ analisou cada *pixel* separadamente para determinar em qual classe (objeto ou fundo) o mesmo pertence. Já a função $B_{\{p,q\}}$ comparou um dado *pixel* aos seus vizinhos. Essa

função de cálculo de energia buscou minimizar a energia total, de modo que os *pixels* que são próximos uns aos outros permanecessem na mesma classe.

Já os autores [Boykov e Jolly \(2001\)](#) propuseram, em seu artigo, um método interativo utilizando um corte em grafo para encontrar o ótimo global de uma segmentação. Antes de realizarem o corte, os autores marcaram uma certa quantidade de *pixels* na imagem, de modo que o primeiro conjunto de *pixels* referiu-se ao objeto que desejaram segmentar e o segundo conjunto referiu-se ao fundo da imagem. Sendo assim, de forma automática, o cálculo do custo entre os vértices foi realizado baseado em termos do limite e nas propriedades de região. Dito isso, com o grafo montado e com seu devido custo entre os vértices estabelecidos, através da aplicação do corte mínimo, foi possível encontrar a segmentação ideal para o problema onde o objeto foi separado da cena. A Figura 13 ilustra o resultado da solução obtida por esses autores.

Figura 13 – Método para segmentação de imagem usando corte em grafo (Fonte: Adaptado de [Boykov e Jolly \(2001\)](#)).



3.2.4 Métricas para a Avaliação das Técnicas de Filtragem e Segmentação das Imagens Tomográficas em Alta Resolução de Sementes Oleaginosas

As métricas utilizadas para a avaliação dos filtros nas imagens digitais podem ser obtidas com base nas medidas de Erro Médio Quadrático (MSE, do inglês *Mean Square Error*), do Pico da Razão Sinal-Ruído (PSNR, do inglês *Peak Signal-to-Noise Ratio*), da Medida do Índice de Similaridade Estrutural (SSIM, do inglês *Structural Similarity Index Measure*) ([DEVNANI; RAWAT, 2016](#)) e do Coeficiente de Similaridade de Dados (DSC, do inglês *Dice Similarity Coefficients*) ([ZOU et al., 2004](#)). O uso da métrica MSE foi obtido considerando a subtração

entre os *pixels* de uma imagem de referência e sua imagem filtrada, sendo definido por:

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (f(x, y) - \hat{f}(x, y))^2 \quad (3.61)$$

onde $f(i, j)$ representa a imagem de referência, $\hat{f}(x, y)$ a imagem filtrada, M o número de linhas e N o número de colunas da matriz imagem. Quanto mais o valor de MSE se aproxima de zero, melhor é a qualidade da imagem filtrada em relação à imagem de referência.

Para a métrica PSNR, definiu-se uma métrica objetiva (FR) que expressou a relação entre a potência máxima de um sinal e a potência do ruído entre uma imagem de referência e a sua imagem filtrada (BGAZO et al., 2011; ROMANI, 2015), sendo representada por:

$$PSNR = 10 \log_{10} \left(\frac{L^2}{MSE} \right) \quad (3.62)$$

onde L denota o valor máximo que pode ser assumido para a intensidade de um *pixel* em uma imagem cuja tonalidade de cinzas é representada por N *bits*. Quanto maior é o valor de PSNR, melhor é a qualidade da imagem filtrada com a presença de ruído em relação à imagem de referência.

A métrica SSIM foi utilizada para medir a similaridade entre uma imagem de referência e sua imagem filtrada (WANG et al., 2004). Seu cálculo foi realizado considerando uma região das imagens sob a análise, assim como as informações sobre os valores baseados em componentes de luminância, de contraste e de estrutura que foram observados nessas janelas (DEVNANI; RAWAT, 2016). Seu valor foi calculado considerando:

$$SSIM(f(x, y), \hat{f}(x, y)) = \frac{(2\mu_{f(x,y)}\mu_{\hat{f}(x,y)} + C_1)(2\sigma_{f(x,y)\hat{f}(x,y)} + C_2)}{(\mu_{f(x,y)}^2 + \mu_{\hat{f}(x,y)}^2 + C_1)(\sigma_{f(x,y)}^2 + \sigma_{\hat{f}(x,y)}^2 + C_2)} \quad (3.63)$$

onde $\mu_{f(x,y)}$ e $\mu_{\hat{f}(x,y)}$ representam médias de $f(x, y)$ e $\hat{f}(x, y)$, $\sigma_{f(x,y)\hat{f}(x,y)}$ a covariância de x e y , $\sigma_{f(x,y)}^2$ e $\sigma_{\hat{f}(x,y)}^2$ as variâncias de $f(x, y)$ e $\hat{f}(x, y)$ e, por fim, C_1 e C_2 são constantes representados por números pequenos que evitam a divisão por zero.

Uma outra métrica utilizada para a avaliação, principalmente nas técnicas de segmentação, baseia-se no cálculo do Coeficiente de Similaridade de Dados (DSC), enquanto o mesmo é definido para avaliar-se o desempenho da similaridade entre uma imagem de referência sobreposta a imagem segmentada (ZOU et al., 2004). O seu valor é calculado como:

$$DSC = \frac{2 \left| \hat{f}(x, y) \cap \hat{f}_s(x, y) \right|}{\left| \hat{f}(x, y) \right| + \left| \hat{f}_s(x, y) \right|} \quad (3.64)$$

onde $\hat{f}(x, y)$ representa a máscara da imagem de referência e $\hat{f}_s(x, y)$ a máscara da imagem segmentada. Quanto o valor da métrica DSC se aproxima de 1, melhor é a qualidade da imagem segmentada em relação à imagem de referência.

3.2.5 Extração de Características

Uma vez realizado o processo de segmentação, onde a imagem foi segmentada em regiões, no processamento da imagem, conseqüentemente, foi considerado posteriormente a fase de extração de características. Esse tipo de análise busca por informações individuais de cada objeto composto na imagem, as quais são obtidas com base no uso de descritores. Os descritores buscam extrair características da imagem para uma representação mais discriminativa, ou seja, dada uma imagem como entrada, sua saída é um conjunto de dados representados por um vetor correspondente à imagem. Esse vetor correspondente à imagem de saída também é chamado de vetor de características que contém informações reduzidas da imagem processada.

Atualmente, existem vários tipos de descritores capazes de especificar características de um objeto contido em uma imagem, seja através de cores, de textura, de contorno, de forma, ou também através da mudança de variação no tamanho, na rotação e na translação. Nessa subsecção, devido aos seus usos neste trabalho, são abordados os métodos de extração de características que são invariantes às transformações geométricas e à textura.

3.2.5.1 *Histogram of Oriented Gradients* (HOG)

Seguindo a teoria dos descritores baseada em gradientes e bordas, o *Histogram of Oriented Gradients* (HOG) foi proposto por Navneet Dalal e Bill Triggs, no ano de 2005 (DALAL; TRIGGS, 2005). O método HOG trata-se de um descritor que calcula a distribuição da orientação de gradientes e das direções das bordas em células da imagem. A imagem é dividida em pequenas regiões espaciais chamadas células e para cada célula acumula-se a direção do gradiente.

De acordo com Dalal e Triggs (2005) e Reis (2011) essa metodologia de extração de característica pode ser dividida em cinco etapas, sendo elas: a normalização de cores, o cálculo do gradiente, o agrupamento dos *pixels* em células, o agrupamento das células em blocos e a obtenção do descritor. A normalização de cores converte a imagem para a escala de cinzas para melhorar a invariância em relação à iluminação (DALAL; TRIGGS, 2005).

Na segunda etapa, foi tratada uma abordagem sobre o gradiente realizando o cálculo em cada *pixel* da imagem. Esse cálculo foi iniciado com a aplicação de um filtro Gaussiano para a suavização, logo após foi utilizado o filtro Sobel como máscara unidimensional de derivada discreta (DALAL; TRIGGS, 2005).

A terceira etapa agrupa os *pixels* em uma determinada região criando-se as chamadas células, de modo que cada célula tenha o mesmo formato em relação às demais. Assim, com a criação das células, o próximo passo trata-se do histograma orientado ao vetor de gradiente que contém a informação do valor de magnitude de acordo com o ângulo de orientação.

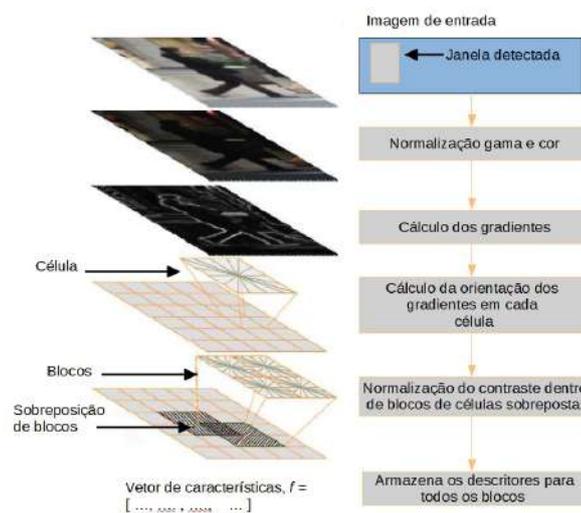
Na quarta etapa, segue o agrupamento das células em blocos de modo que os blocos possuem um formato e tamanho fixo. Ainda nessa etapa, é feita a normalização para que o

resultado seja invariante à iluminação.

Na quinta e última etapa, com os histogramas obtidos no passo anterior, cria-se um descritor contendo uma lista de histograma com todos os blocos normalizados. Esse descritor tem como estrutura de dados a representação por um vetor, sendo que cada posição contém a característica extraída do objeto.

Nesse contexto, a metodologia aplicada pelo descritor HOG é realizada em vários estágios, como pode ser observado na Figura 14. Posteriormente, iniciou-se o estágio que foi compartilhado de cada célula em blocos até a geração do vetor de descritores obtidos pelos blocos normalizados.

Figura 14 – Representação do funcionamento do descritor HOG (Fonte: Adaptado de Dalal (2006)).



3.2.5.2 Momentos Invariantes

Os Momentos Invariantes (MIs) foram introduzidos em 1962 como uma ferramenta para o reconhecimento de padrões e análise em figuras geométricas. Sendo assim, os MIs surgiram quando Hu os aplicou em um cálculo de derivação em um conjunto de momentos baseando-se na teoria dos momentos invariantes algébricos (HU, 1962). Dessa forma, para obter os setes momentos invariantes Hu, considerado como os momentos invariantes em relação à rotação, à translação e à escala, foi preciso, primeiramente, o conhecimento *a priori* dos momentos bidimensionais, dos momentos centrais e dos momentos centrais normalizados.

3.2.5.2.1 Momentos Bidimensionais

Os momentos bidimensionais são funções projetadas em $f(x,y)$, representadas por uma função polinomial. Esses momentos são definidos considerando uma ordem $(p + q)$ de uma imagem digital $f(x,y)$, através da integral de Reimann (HU, 1962), sendo representada pela

equação:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy, \quad (3.65)$$

para $p, q = 0, 1, 2, \dots, \infty$.

Sendo assim, m_{pq} são os momentos bidimensionais de uma função $f(x, y)$. Nesse contexto, quando os momentos bidimensionais são m_{00} , eles correspondem à área da região de uma imagem. Além disso, os momentos m_{01} e m_{10} correspondem às coordenadas do centro de massa da região.

3.2.5.2.2 Momentos Centrais

Os momentos centrais são momentos centralizados em regiões, o que permite ser invariante a transformação de translação e de rotação. Seu cálculo de ordem $(p + q)$ é definido como:

$$\mu_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{x})^p (y - \bar{y})^q f(x, y) dx dy, \quad \text{para } p, q = 1, 2, \dots \quad (3.66)$$

onde

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad (3.67)$$

$$\bar{y} = \frac{m_{01}}{m_{00}} \quad (3.68)$$

de forma que as variáveis \bar{x} e \bar{y} correspondem às coordenadas do centro de massa de uma imagem $f(x, y)$.

3.2.5.2.3 Momentos Centrais Normalizados

Os momentos centrais normalizados permitem que os momentos centrais da equação 3.66 sejam invariantes à transformação de escala. Essa invariância à transformação de escala foi denotada por η_{pq} da equação 3.69:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^{\gamma}} \quad \text{para } p, q = 2, 3, \dots \quad (3.69)$$

sendo a expressão γ representada por:

$$\gamma = \frac{p + q}{2} + 1 \quad \text{para } p, q = 2, 3, \dots \quad (3.70)$$

3.2.5.2.4 Momentos Invariantes de Hu

A partir da combinação linear dos momentos centrais de segunda e de terceira ordem, Hu (1962) definiu uma combinação composta por 7 equações invariantes à translação, à rotação, à escala e ao espelhamento, a qual foi dado o nome de momentos invariantes de Hu. Os momentos

invariantes de Hu foram compostos pelas derivadas de segundo e de terceiro momento central, sendo eles definidos pelas equações:

$$\phi_1 = \eta_{20} + \eta_{02} \tag{3.71}$$

$$\phi_2 = (\eta_{20} + \eta_{02})^2 + 4\eta_{11}^2 \tag{3.72}$$

$$\phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \tag{3.73}$$

$$\phi_4 = (\eta_{30} + 3\eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \tag{3.74}$$

$$\phi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + 3\eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) [3(\eta_{30} + 3\eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \tag{3.75}$$

$$\phi_6 = (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \tag{3.76}$$

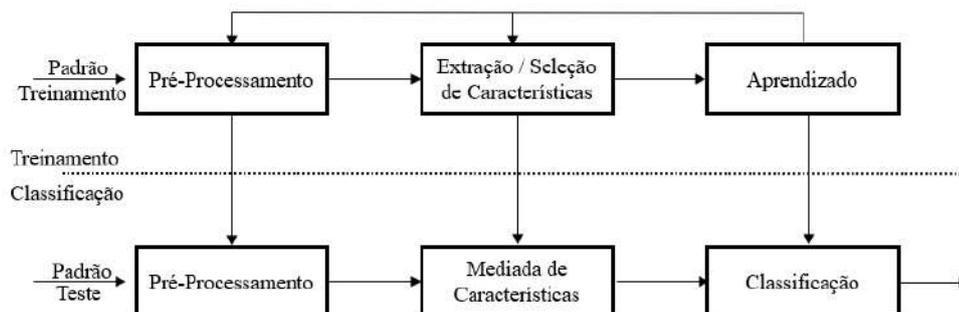
$$\phi_7 = (3\eta_{21} - \eta_{30})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) [3(\eta_{30} + 3\eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \tag{3.77}$$

Os momentos invariantes de ϕ_1 ao ϕ_6 são invariantes à rotação, à escala e à translação. O ϕ_7 momento invariante é o espelhamento da imagem.

3.3 Classificadores de Padrões

Para a classificação de objetos em imagens é usual utilizar como *a priori* o reconhecimento de padrões. A Figura 15 ilustra de forma simplificada mecanismos e técnicas que podem ser aplicadas para o reconhecimento de padrões em uma imagem digital.

Figura 15 – Representação ilustrativa do modelo aplicado para o reconhecimento de padrões (Fonte: Adaptado de Jain et al. (2000)).



Neste contexto, o reconhecimento de padrões é baseado no estudo de como as máquinas conseguem observar o ambiente, de modo que elas aprendem a distinguir padrões de interesse e a tomar decisões sólidas e razoáveis em relação às categorias dos padrões (JAIN et al., 2000). Segundo Gonzalez e Woods (2007), o reconhecimento de padrões foi definido como uma técnica fundamental na análise de imagens voltada ao processamento de alto nível.

Um padrão é formado por uma estrutura de dados quantitativos e qualitativos que representam alguma entidade na imagem (ALVES, 2006), ou pode ser considerado como um tipo, ou como um conjunto de eventos recorrentes de objetos (SANTOS, 2009). De modo geral, um padrão é identificado por um ou mais descritores, sendo que cada elemento contido dentro dos descritores contém as informações simplificadas sobre uma entidade ou um objeto presente em uma imagem. Cada padrão é formado por um vetor de características, de forma que cada vetor tem a seguinte estrutura:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (3.78)$$

onde cada componente x_i representa o i -ésimo descritor e n representa o número referente a esse descritor.

As abordagens utilizadas na etapa de reconhecimento de padrões tratam-se de métodos de reconhecimento por decisão teórica, de métodos estruturais para o reconhecimento e de métodos para a interpretação de imagens.

Nos métodos de reconhecimento, por decisão teórica, os padrões são representados em forma de um vetor buscando as abordagens para agrupar e atribuir a uma classe que representa um conjunto de padrões que possuem propriedades em comum. Os classificadores utilizados nessas abordagens são: a distância mínima, as redes neurais, o classificador Bayesianos, entre outros (GONZALEZ; WOODS, 2007).

Nos métodos estruturais são utilizados os padrões de cadeias e árvores como forma simbólica de representação. Os métodos de reconhecimento de padrões também podem utilizar modelos que tratam esses padrões como entes simbólicos que são entendidos como sentenças ou frases por sistemas de inteligência artificial.

Os métodos para a interpretação de imagens se baseiam na atribuição de significados a um conjunto de elementos, de forma que se tenha o conhecimento sobre o domínio do problema. Um exemplo de técnicas que utilizam essas abordagens são as lógicas de predicados, as redes semânticas e os sistemas de produção (BISHOP, 2006; GONZALEZ; WOODS, 2007).

Os classificadores são utilizados para classificar padrões que foram previamente estabelecidos, de modo que qualificam com maior precisão a qual classe pertenceu os conjuntos instanciados (JAIN et al., 2000).

3.3.1 Aprendizado Supervisionado

Aprendizado supervisionado é de conhecimento do sistema assim como a existência de um conjunto de objetos treinados e pré classificados, de modo que cada objeto tenha uma classe definida e sirva como modelo para classificar os demais objetos (DUDA et al., 2000; COSTA; CESAR JR., 2000).

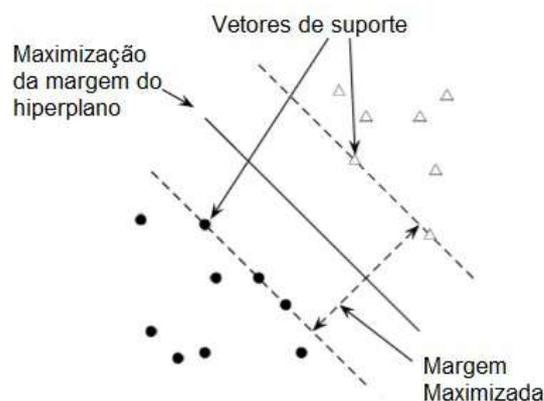
3.3.1.1 Máquina de Vetores de Suporte (*Support Vector Machine - SVM*)

Desenvolvida na década de 1990 por Boser, Gyon e Vapnik, a Máquina de Vetores de Suporte (SVM - *Support Vector Machine*) é uma técnica de classificação supervisionada utilizada na etapa de reconhecimento de padrões para a classificação e a análise de regressão (BOSER et al., 1992; CORTES; VAPNIK, 1995).

Segundo Cortes e Vapnik (1995), o SVM é aplicado para resolver problemas de classificação entre dois conjuntos. Dessa forma, cada conjunto de dados de entrada é representado por vetores de características que ao decorrer de sua implementação são mapeados de forma não linear em um espaço de alta dimensionalidade. Já Lorena e Carvalho (2007) citam em seu trabalho as vantagens de se utilizar o classificador SVM, devido ao seu desempenho em alguns casos, tornando-o superior às Redes Neurais Artificiais (RNAs) também pela sua capacidade de generalização.

O principal objetivo do classificador SVM é o de construir um hiperplano (ou fronteira de decisão) que separa dois conjuntos de dados de treinamento em uma superfície de decisão, de modo que é maximizado a distância entre as duas classes com uma maior margem possível (BOSER et al., 1992). A margem é uma reta paralela ao hiperplano, sendo ela representada como uma medida de separação entre as duas classes. Cada um dos vetores de características que estão localizados sobre a margem são chamados de vetores de suporte. A Figura 16 ilustra um exemplo de classificador SVM linear representado por duas classes distintas em círculos e triângulos.

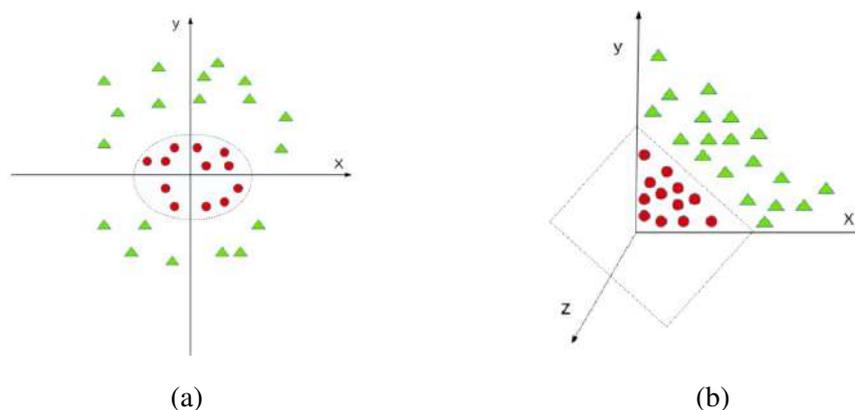
Figura 16 – Representação ilustrativa do classificador SVM, indicando a margem e os vetores de suporte (Fonte: Adaptado de Schütze et al. (2007)).



No ano de 1995, os autores Cortes e Vapnik implementaram um novo conceito evoluindo o método original tratando as variáveis de folga. Essas variáveis de folga permitem ao classificador encontrar um hiperplano ideal com margens mais flexíveis quando os conjuntos de dados não são linearmente separáveis (CORTES; VAPNIK, 1995).

Para os classificadores SVM não lineares utiliza-se uma propriedade matemática chamada *KERNEL*. Essa função que realiza o mapeamento de um conjunto de dados de entrada para um espaço de alta dimensão. Desse modo, ao aplicar o mapeamento, os dados se tornam linearmente separáveis no hiperplano. Um exemplo ilustrativo do classificador SVM não linear pode ser observado, conforme apresentado na Figura 17, onde a imagem que aparece ao lado esquerdo desse exemplo é referente aos dois conjuntos de dados não linearmente separáveis e à direita se tem uma imagem referente a um espaço tridimensional com dois conjuntos de dados linearmente separáveis.

Figura 17 – Representação da função KERNEL do espaço bidimensional (Figura 17a) e o espaço tridimensional (Figura 17b) (Fonte: Adaptado de Cristianini e Shawe-Taylor (2000)).



Entre os KERNELs mais comuns utilizados pelo SVM são encontrados aqueles que são citados nos trabalhos de Guyon e colaboradores, assim como o de Lorena e Carvalho (GUYON et al., 1992; LORENA; CARVALHO, 2007). Nesse contexto, foram encontrados os seguintes KERNELs:

- KERNEL polinomial: é um kernel polinomial de ordem q representado pela equação:

$$K(x, x') = (x \cdot x' + 1)^q \quad (3.79)$$

onde x e x' definem os dados de entrada do classificador e o parâmetro q é o grau do polinômio a ser utilizado.

- KERNEL RBF (*Radial Basis Function*): também chamando de Kernel Gaussiano, podendo ser representado pela equação:

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (3.80)$$

onde x e x' definem os dados de entrada do classificador e o parâmetro ι é função base do radial.

- KERNEL Sigmoidal: possui equivalência à uma rede neural, sendo representado por:

$$K(x, x') = \tanh(\gamma(x \cdot x') + r) \quad (3.81)$$

onde x e x' definem os dados de entrada do classificador, o parâmetro γ é núcleo do sigmoide e r é a constante de interceptação.

3.3.1.2 Classificador Bayesiano

O classificador Bayesiano é um método de classificação probabilístico baseado no Teorema de Bayes designado para a distribuição de probabilidades em um conjunto de padrões pertencentes a cada classe (LANGLEY et al., 1992; DUDA et al., 2000). Essa abordagem de classificação é um método usado em análise de dados e reconhecimento de padrões que requer a construção de um classificador de forma que, a cada conjunto de atributos, atribuímos um rótulo a essas instâncias (FRIEDMAN et al., 1997).

Ao utilizar o classificador Bayesiano, supõe-se que cada classe w_i do problema tem como probabilidade *a priori* uma representação $P(w_i)$. Sendo assim, ao considerar um vetor X e a função de densidade condicional $p(X|w_i)$, é denotado qual é a probabilidade de X pertencer à classe w_i . Dessa forma, o classificador Bayesiano por meio do cálculo probabilístico *a posteriori* do objeto analisado da classe w_i ocorrer em X aplicando à equação:

$$P(w_i|X) = \frac{P(w_i)p(X|w_i)}{p(X)} \quad (3.82)$$

sendo, $P(w_i)$ a probabilidade *a priori* de w_i , a função $P(w_i|X)$ a probabilidade *a posteriori* de w_i dado a ocorrência de X , $p(X|w_i)$ a densidade condicional ou verossimilhança e, por fim, $p(X)$ é a evidência. Desde modo, quando o problema apresenta mais de uma classe, a equação 3.82 será modificada para equação:

$$p(X) = \sum_{i=1}^N p(X|w_i) \cdot P(w_i) \quad (3.83)$$

onde é considerado o valor de N como o número total de classes do problema.

Um fato a ser observado na terminologia da teoria dos classificadores Bayesianos é o critério de escolha da classe que maximize a probabilidade *a posteriori* ou a minimização de erro ao selecionar uma classe. Esse critério leva a utilizar como tomada de decisão o classificador máximo de probabilidade *a posteriori* (MAP), expresso pela equação:

$$w^* = \operatorname{argmax}_{w_i} P(w_i|x) \quad (3.84)$$

a expressão *argmax* é responsável por maximizar a probabilidade *a posteriori* dada quando i obtém um valor máximo em relação aos demais. Sendo assim, a classe que obter o maior valor de

i representa a decisão é feita a seu favor (DUDA et al., 2000; JIANG et al., 2005; CERQUEIRA, 2010).

Entre os algoritmos de aprendizado probabilísticos, da família dos classificadores Bayesianos, conhecidos na literatura, estão os classificadores Naïve Bayes (CESTNIK, 1990), KDB (SAHAMI, 1996; SANTOS, 2007), TAN (FRIEDMAN et al., 1997; SANTOS, 2007) e Semi-Naïve (KONONENKO, 1991; SANTOS, 2007). A partir do teorema de Bayes foi encontrado o classificador Naïve Bayes, o qual é considerado um classificador eficiente, devido ao fato dele assumir que as probabilidades de todos os atributos são independentes quando condicionados às classes, ou seja, não há um relacionamento entre os atributos (CESTNIK, 1990; ZHANG, 2004; WEBB et al., 2005). Com isso, essa suposição pode ser representada como:

$$p(a|C) = p(a_1, a_2, \dots, a_n|C) = \prod_{i=1}^n p(a_i|C) \quad (3.85)$$

onde assume-se que cada valor ocorrente de a_j são estatisticamente independentes em relação à qualquer outro valor de a_j , dado a classe C .

Assim, a equação 3.85 ao ser aplicada à fórmula matemática do classificador Bayesiano, representada pela equação 3.82, passa a ser aplicada à chamada regra Naïve Bayes.

3.3.2 Aprendizado Não Supervisionado

No aprendizado não supervisionado ou também chamado de *clustering*, o sistema não possui nenhum conhecimento de um conjunto pré definido. Sendo assim, o seu objetivo é aprender a construir e agrupar cada objeto que possua alguma característica de similaridade entre si, de modo que se formem grupos ou clusters desses objetos (COSTA; CESAR JR., 2000; FERNÁNDEZ, 2011). Nesse contexto, os métodos de aprendizado não supervisionado podem ser divididos em duas abordagens, a paramétrica e a não paramétrica. Na abordagem paramétrica, busca-se definir critérios de agrupamento, por exemplo, as medidas de separabilidade de classe para que se tenha uma melhor eficiência na classificação. Na abordagem não paramétrica, assume-se que cada amostra é separada de acordo com as suas características, de modo que as amostras tenham nenhum critério ou fórmula matemática para o agrupamento das amostras.

Atualmente, métodos de aprendizado não supervisionado são vistos na literatura como técnicas fundamentadas em: *K-Means* (HARTIGAN; WONG, 1979), *Clustering*, (GEARY et al., 1989), *Mixture Models Gaussian* (FIGUEIREDO; JAIN, 2002), entre outros métodos.

3.3.3 Aprendizado Semi-Supervisionado

No aprendizado semi-supervisionado, o conjunto de dados é dividido em objetos com rótulos de classe e objetos que não possuem rótulos. Logo, o seu objetivo é realizar uma combinação dos dados rotulados e não rotulados que visam e auxiliam projetar um algoritmo de

classificação que utilize técnicas de agrupamento quanto a necessidade de se utilizar técnicas de aprendizado supervisionado para integrem um determinado sistema (CHAPELLE et al., 2009).

3.4 Análise de Componentes Principais

A Análise de Componentes Principais (PCA, do termo inglês "*Principal Component Analysis*") foi introduzida na área de estatística, em 1901, por Karl Pearson, como uma técnica para analisar e resolver problemas de como encontrar "linhas e planos mais próximos dos sistemas de pontos no espaço" (PEARSON, 1901; WOLD et al., 1987). No entanto, Hotelling, no ano de 1933, descreveu em seu artigo o primeiro desenvolvimento teórico dando o nome de métodos de componentes principais (HOTELLING, 1933). Deste então, a técnica aplicada pela PCA, também conhecida pelo nome de técnica estatística multivariada, vem sendo utilizada em diversas áreas com o objetivo de reduzir a dimensionalidade de um conjunto de dados (VARELLA, 2008).

A modelagem matemática aplicada pela técnica PCA consiste em uma utilizar uma matriz de dados X com n amostras que representam o número de observações e m variáveis independentes, ou seja:

$$X = \begin{Bmatrix} x_{11} & \cdots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nm} \end{Bmatrix} \quad (3.86)$$

A partir do estabelecimento dessa matriz, o próximo passo para se obter os componentes principais consiste em padronizar os dados e em calcular a matriz de correlação, de modo que a matriz de dados X gere uma matriz de dados Z . Dessa forma, os valores dos elementos z_{ij} da matriz Z são calculados conforme a expressão:

$$z_{i,j} = \frac{x_{ij} - \bar{x}_j}{s_j}, \quad i = 1, 2, 3, \dots, n \text{ e } j = 1, 2, 3, \dots, m \quad (3.87)$$

onde \bar{x}_j é a média estimada da coluna (variável) j , conforme expressa a equação:

$$\bar{x}_j = \frac{\sum_{i=1}^n X_{ij}}{n}, \quad i = 1, 2, 3, \dots, n \text{ e } j = 1, 2, 3, \dots, m \quad (3.88)$$

e s_j é o desvio padrão da coluna (variável) j , conforme expressa a equação:

$$s_j = \sqrt{\hat{V}ar(x_j)}, \quad j = 1, 2, 3, \dots, m \quad (3.89)$$

Logo, após a padronização da matriz foi obtida uma nova matriz de dados Z , ou seja:

$$Z = \begin{Bmatrix} z_{11} & \cdots & z_{1m} \\ \vdots & \ddots & \vdots \\ z_{n1} & \cdots & z_{nm} \end{Bmatrix} \quad (3.90)$$

Sendo assim, com a matriz de dados Z das variáveis padronizadas, z_j igual a matriz de dados X , inicia-se o cálculo da matriz de correlação amostral R expressa pela equação:

$$R = \frac{1}{n-1}(Z^t Z) \quad (3.91)$$

De forma adicional, ao realizar o cálculo da correlação amostral com base nos dados padronizados, foi iniciado o cálculo para determinar os componentes principais conforme os autovalores e autovetores. Nesse caso, uma vez dados os autovalores, $\lambda_1, \lambda_2, \dots, \lambda_m$ são determinados sob a matriz de correlação com dimensão $m \times m$, de forma que:

$$\det = |R - \lambda I| = 0 \quad (3.92)$$

onde I significa a matriz identidade de ordem m .

Com propriedade de dimensão m , os autovetores $\mu_1, \mu_2, \dots, \mu_m$ são calculados conforme a equação:

$$R\mu = \lambda\mu \quad (3.93)$$

sendo assim, para cada autovalor λ_i existe um autovetor μ_i correspondente.

A solução obtida no cálculo dos autovetores da equação 3.93 resulta em um vetor não normalizado com m autovetores. Sendo assim, é possível obter a normalização dos autovetores, ou seja:

$$v_j = \frac{1}{\mu_j^t \mu_j} \mu_j \quad (3.94)$$

Com isso, ao realizar o cálculo da normalização dos autovetores, os m autovetores passam a representar o resultado final ou as componentes principais para análise.

3.5 Considerações Finais

Ao longo desse Capítulo foram apresentados os referenciais teóricos das técnicas utilizadas para o desenvolvimento do método de classificação de sementes agrícolas baseados no processamento digital de imagens. No Capítulo seguinte serão apresentadas a organização das bases de imagens tomográficas em alta resolução, a estruturação do método e os algoritmos desenvolvidos.

Capítulo 4

MATERIAIS E MÉTODOS

Neste Capítulo serão apresentados os materiais e métodos utilizados no desenvolvimento do trabalho. Nesse contexto, serão apresentadas as bases das fatias tomográficas de alta resolução que foram obtidas a partir do ensaio de sementes agrícolas oleaginosas. Também serão apresentados os diversos algoritmos desenvolvidos com base em técnicas do processamento de imagens, incluindo o reconhecimento de padrões e a extração de características. Ademais, será observado o uso da técnica de análise de componentes principais utilizada para a composição da abordagem baseada em HOG e nos momentos invariantes de Hu visando, dessa forma, uma classificação adequada e adaptativa aos diferentes tipos de sementes agrícolas analisadas.

4.1 Sementes Agrícolas

Para a classificação de imagens tomográficas, em alta resolução, de sementes oleaginosas, foram escolhidas para os ensaios as sementes da cultura de girassol, do pinhão-manso e da soja.

4.1.1 Girassol

O Girassol ou *Helianthus annuus L.*, como é chamado cientificamente, é uma planta originária do continente Norte-Americano pertencente à família das *Compositae* (CASTRO et al., 1996). Neste conceito de sementes oleaginosas, as sementes de girassol são ricas em nutrientes como fonte de proteínas, de fibras e de vitamina E. Além disso, a sua matéria-prima é considerada uma das principais sementes oleaginosas produtoras de biodiesel (CASTRO et al., 1996; COSTA; MARCHI, 2008; BELTRÃO; OLIVEIRA, 2008). A Figura 18 ilustra um conjunto de sementes pertencente à cultura de Girassol.

As sementes de girassol possuem uma coloração cinza-escuro e características agrônômicas resistentes à seca, ao frio e às pragas. Devido a esses atributos, as sementes são adaptáveis às condições edafoclimáticas podendo tolerar temperaturas baixas e estresses hídricos (HELENA et al., 2001).

Figura 18 – Representação ilustrativa de sementes de girassol.



4.1.2 Pinhão-mansó

O Pinhão-mansó ou *Jatropha curcas L.*, como é conhecido no ambiente científico, é um vegetal da espécie nativa do Brasil pertencente à família das Euforbiáceas (ARRUDA et al., 2004). A espécie tem destaque na sociedade por se tratar de uma planta oleaginosa que possui sementes adaptáveis em diversos ambientes e climas edafoclimáticos, além disso, ela é uma semente de baixo custo de armazenamento (TOUCHELL; DIXON, 1994; ARRUDA et al., 2004; SATURNINO et al., 2005). A Figura 19 ilustra um conjunto de sementes pertencente à cultura de pinhão-mansó.

Figura 19 – Representação ilustrativa de sementes de pinhão-mansó.



Semelhante as condições climáticas necessárias para a produção do girassol, a semente do pinhão-mansó pode tolerar temperaturas médias, elevadas e ela é exigente em relação à insolação e resistente à seca (HELENA et al., 2001; ARRUDA et al., 2004; GOLDFARB et al., 2010).

4.1.3 Soja

A Soja (*Glycine max (L.) Merrill*) é uma das principais culturas de sementes oleaginosas existentes no mundo. Neste conceito de sementes oleaginosas, a semente de soja possui as características de fonte primária o óleo e a proteína vegetal, sendo ela também uma alternativa

essencial para a produção de biocombustíveis (FRANÇA-NETO et al., 1988; CAVALCANTE et al., 2011). A Figura 20 ilustra um conjunto de sementes pertencente à cultura da Soja.

Figura 20 – Representação ilustrativa de sementes de soja.



No cenário econômico, a soja é utilizada como fonte alternativa para a diminuição de derivados do petróleo, a qual gera, assim, a economia alternativa para o abastecimento de veículos e para os benefícios ambientais (ALMEIDA et al., 2010).

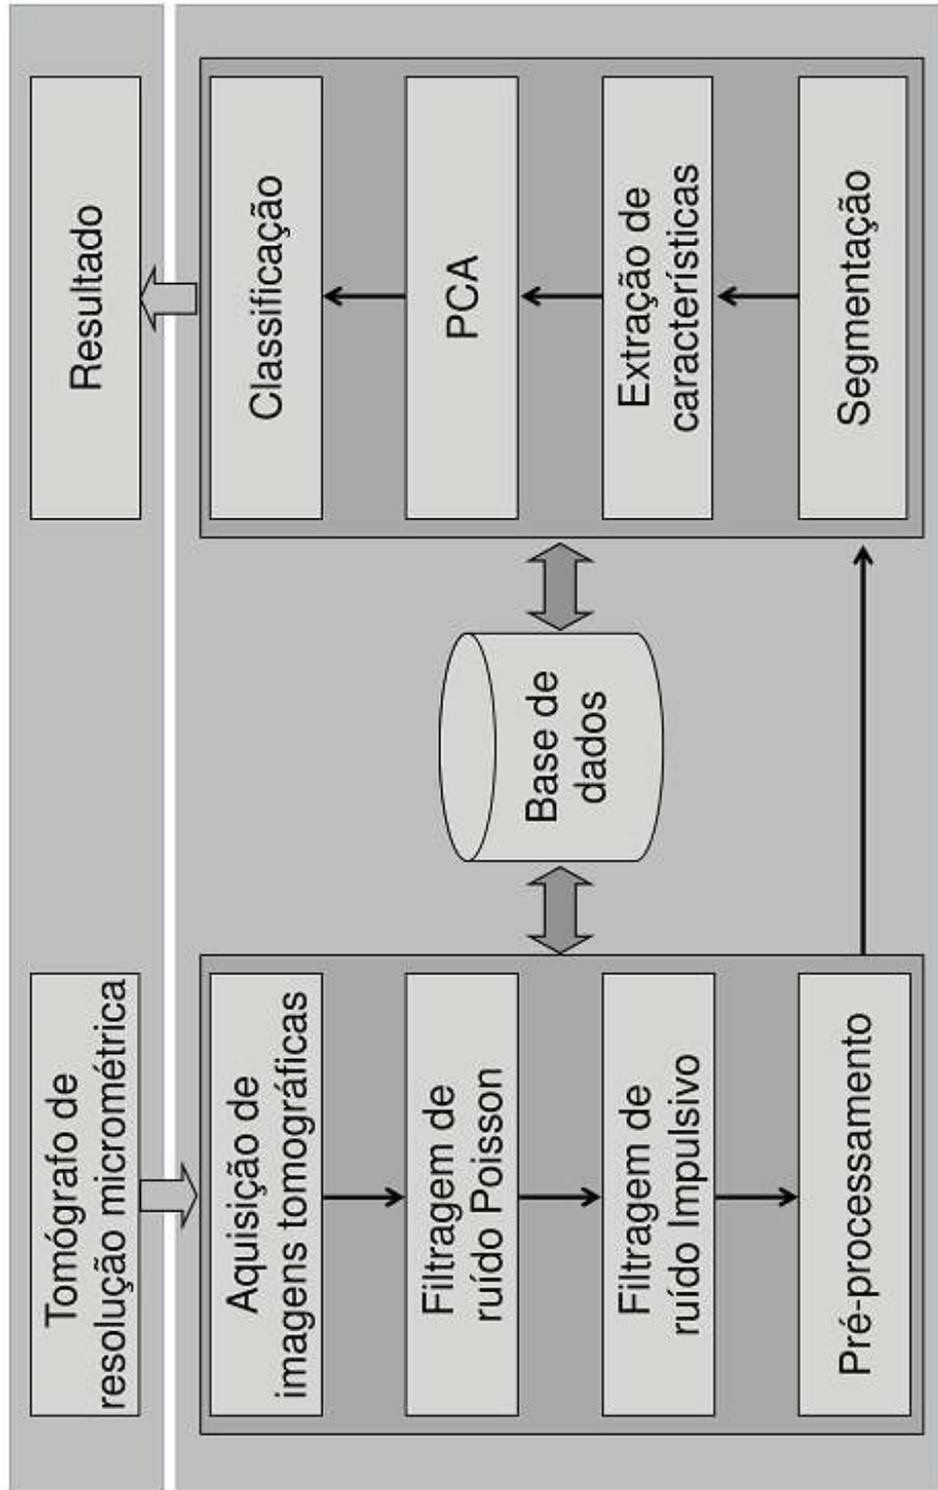
4.2 Modelagem do Sistema

Esta seção tem como objetivo desenvolver um modelo para reconhecer padrões em fatias tomográficas referentes às sementes de girassol, de pinhão-manso e de soja (Figura 21).

Para o reconhecimento de padrões das sementes agrícolas foram necessárias diversas etapas, como: a base de dados das culturas agregado a aquisição das fatias tomográficas de raios-X de alta resolução; o pré-processamento das fatias tomográficas e a seleção de diferentes tipos de filtros para cada modalidade de sementes agrícolas ensaiadas; o uso de métricas de análises da qualidade das fatias tomográficas resultantes para avaliar o método ideal ou o mais adequado nas etapas de filtragem; a segmentação das fatias tomográficas; o estabelecimento de descritores de características; a análise de componentes principais para reduzir a dimensionalidade da variabilidade do vetor de características de forma e de textura; a avaliação de métodos de classificação supervisionada para o auxílio à tomada de decisão a partir de padrões apreendidos e testados para cada espécie de semente agrícola ensaiada.

Neste contexto, a concepção do método leva em conta o armazenamento parcial e total das bases de fatias tomográficas e dos dados obtidos nas diferentes etapas do processamento. Sendo assim, a base de dados compõe-se dos resultados de fatias tomográficas obtidos nas etapas de filtragem e de segmentação. São eles dados numéricos das métricas para a avaliação, a extração de características e os resultados das análises de componentes principais, envolvendo etapas de treinamento e de testes de validação para classificadores das sementes agrícolas.

Figura 21 – Diagrama de blocos dos métodos baseado em visão computacional e reconhecimento de padrões para de sementes agrícolas (Fonte - Elaborado pelo autor).



4.2.1 Aquisição e organização das fatias tomográficas

A Figura 22 apresenta a foto do tomógrafo de resolução micrométrica instalado no laboratório de técnicas nucleares da Embrapa Instrumentação, o qual foi utilizado no desenvolvimento deste trabalho.

Figura 22 – Foto do tomógrafo de alta resolução modelo SkyScan 1172 (Fonte: [SkyScan 1172 user manual](#)).



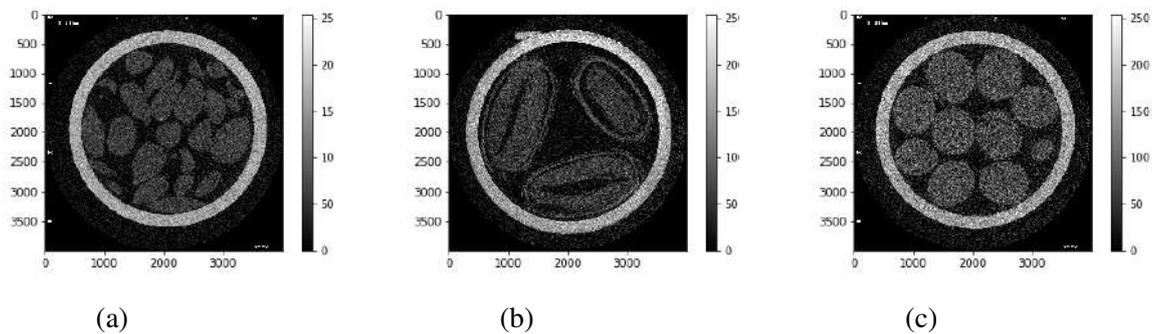
Neste contexto, a Tabela 1 apresenta os parâmetros utilizados para a aquisição das fatias tomográficas de alta resolução do conjunto de amostras de sementes agrícolas de girassol, de pinhão-mansão e de soja.

Tabela 1 – Parâmetros para aquisição das fatias tomográficas.

CCD	10Mp
Tamanho <i>pixel</i>	8,54 μ m
Alimentação do raio-X	100kV
Corrente	100 μ A
Tempo de aquisição tomográfica	05h:32min/amostra
Tipo do arquivo	.bmp
Tamanho da fatia tomográfica	1134 kBytes
Largura da fatia tomográfica	4000 <i>pixels</i>
Altura da fatia tomográfica	4000 <i>pixels</i>

Foram adquiridas 5693 fatias tomográficas para cada tipo de semente ensaiada, assim como um número igual para a amostra composta preparada com os três tipos de sementes, logo, perfazendo um total de 22772 fatias tomográficas. A Figura 23 ilustra exemplos de fatias tomográficas bidimensionais obtidas para cada tipo de semente ensaiada.

Figura 23 – Exemplo de fatias tomográficas referentes às sementes de girassol (23a), de pinhão-manso (23b) e de soja (23c).



As fatias tomográficas obtidas por tomografia de raios-X possuem predominantemente a presença de ruído *Poisson*. Esse tipo de ruído tem o comportamento aleatório e a influência na contagem dos fótons durante o processo de coleta das projeções tomográficas de raios-X ou γ (RIBEIRO, 2010; PINHEIRO, 2017). Entretanto, há outros tipos de ruídos que estão associados ao processo da tomografia de raios-X, dentre eles se encontram os ruídos decorrentes de vibrações mecânicas da mesa tomográfica, os ruídos decorrentes das variações de temperatura e os seus impactos na eletrônica utilizados no processamento dos sinais, os ruídos decorrentes das transmissões e das comunicações desses sinais ao longo da cadeia nuclear dos instrumentos de medição, bem como as suas conexões para o acesso aos computadores de controle e de processamento, assim como os ruídos decorrentes do uso de diferentes algoritmos de reconstrução das fatias tomográficas, dentre outros (LAIA et al., 2011). As projeções tomográficas obtidas pelo uso do tomógrafo SkyScan 1172 são fatias tomográficas reconstruídas que passaram por um processo de filtragem que enfatizaram a minimização do ruído *Poisson*, o qual é *a priori* do processo de reconstrução. Logo, neste trabalho, a maior atenção é dada à filtragem de ruídos nas fatias já reconstruídas, observando o uso de modelos que consideram os ruídos (modalidade de ruído Gaussiano e ruído impulsivo) e as fatias tomográficas assim como em técnicas de filtragem.

Sendo assim, posteriormente, no término do processo das projeções tomográficas e da reconstrução foram avaliados os filtros visando a qualidade das fatias tomográficas na etapa do pré-processamento.

4.2.2 Qualificação da base de fatias tomográficas

Foram adquiridas fatias tomográficas referentes às sementes de girassol, ao pinhão-manso e à soja, sendo utilizadas neste trabalho 5693 fatias tomográficas de cada modalidade de sementes.

De acordo com o cálculo de amostragem, para determinar o número amostral de fatias tomográficas de sementes agrícolas nessa pesquisa, foi realizado o cálculo estatístico por meio da

calculadora online Solvis¹. Assim, tendo como base o número total de 22772 fatias tomográficas utilizando um nível de confiabilidade de 90% e uma margem de erro de 2,94%, a amostra representativa de 812 fatias tomográficas foram utilizadas para a avaliação das técnicas do processamento de imagens para a composição do método de classificação das sementes agrícolas oleaginosas sem defeito e para as sementes agrícolas oleaginosas com defeito.

Essas 812 fatias foram agrupadas em sete diferentes bancos de fatias tomográficas referentes a cada cultura de semente com defeito e sem defeito, contendo também uma base de fatias tomográficas adicional com os três tipos de sementes. Sendo assim, cada um desses bancos foram alocados em 116 fatias tomográficas de cada modalidade de semente, incluindo para cada modalidade o banco de fatias tomográficas de sementes com defeitos e o banco de fatias tomográficas de sementes sem defeitos. O processo de alocação dessas fatias nos respectivos bancos de fatias tomográficas de sementes ocorreu a partir de uma busca aleatória no banco total da amostra das fatias tomográficas que respeitaram a modalidade das sementes utilizadas.

4.2.3 Pré-Processamento

Em função da observação das fatias tomográficas obtidas por tomografia de raios-X, o primeiro método de filtragem utilizado foi o filtro de difusão anisotrópico. Esse filtro foi aplicado no domínio espacial de modo que a fatia de entrada passa por um processo de filtragem com inúmeras iterações. Dessa maneira, conforme o pseudocódigo 1 (Apêndice A), foi especificado o valor de κ que é referente à sensibilidade da borda, enquanto que a variável Γ representa o tempo de iteração e o *numIter* o número de vezes que o filtro é aplicado na fatia tomográfica.

O segundo método de filtragem utilizado para avaliação foi o filtro Passa-Banda Ideal. Esse filtro foi aplicado no domínio da frequência de forma que a fatia tomográfica de entrada contida no domínio do espaço foi transformada para que o mesmo fosse aplicado o filtro. O pseudocódigo 2 (Apêndice A) ilustra o algoritmo utilizado. As variáveis σ_1 e σ_2 são referentes aos valores utilizados para removerem altas e baixas frequências na função.

O terceiro método de filtragem avaliado foi o filtro Gaussiano. Ele foi aplicado no domínio espacial ao passo que a fatia tomográfica de entrada passa por uma convolução com o kernel Gaussiano. Desse modo, são especificados os valores positivos ímpares para largura e altura do kernel, assim como o valor para o σ representa o desvio padrão. O pseudocódigo 3 (Apêndice A) ilustra o algoritmo utilizado.

O quarto método de filtragem utilizado para avaliação foi o filtro *Non-local Means*. Esse filtro foi aplicado no domínio espacial de maneira que são extraídos pequenos *patches*, no qual o *pixel* de interesse está localizado na região central e comparado aos outros *patches* de sua vizinhança. Sendo assim, o *pixel* foi substituído pela média da seleção dos *patches* vizinhos. Dessa forma, foi especificado o método com atributos de tamanho do *patche*, distância entre eles

¹ <https://www.solvis.com.br/calculos-de-amostragem/>

e de σ para o desvio padrão. O seu algoritmo é apresentado pelo pseudocódigo 4 (Apêndice A).

4.2.4 Segmentação

Os métodos de segmentação aplicados neste trabalho levam em conta a separação do objeto (sementes agrícolas) do fundo das fatias tomográficas processadas. As fatias tomográficas analisadas passaram por um processo de pré filtragem *a priori* tanto em termos do ruído *Poisson* (filtragem *a priori* nas projeções tomográficas) quanto em termos das fatias reconstruídas para a filtragem de possíveis ruídos do tipo impulsivo (neste caso, utilizando a filtragem espacial com o filtro de mediana) (PEREIRA, 2007).

Para realizar a segmentação foram avaliados os métodos de Limiarização por histograma, Otsu e Grafo. Esses métodos foram avaliados de forma a encontrar para cada tipo de semente aquele que se apresenta como a melhor opção para o estabelecimento do método de classificação.

4.2.4.1 Segmentação utilizando a técnica de Limiarização

A equalização do histograma redistribui uniformemente a intensidade dos *pixels* no histograma da fatia tomográfica suavizada, assim, melhorando o contraste da fatia tomográfica sem alterar o seu conteúdo. Logo, após a equalização do histograma, foi escolhido manualmente um limiar que possibilitou separar a fatia tomográfica em duas classes, tendo como base os valores atribuídos aos *pixels*. Neste contexto, cada classe passa a conter os valores binários conforme foi estabelecido pelo pseudocódigo 5 (Apêndice A).

4.2.4.2 Segmentação utilizando a técnica de Otsu

A segmentação pela técnica de Otsu se diferencia da técnica de limiarização no âmbito de determinar um valor para o seu limiar. Sendo assim, o limiar aplicado à técnica de Otsu foi baseado literalmente em cálculos matemáticos executados sobre o histograma da fatia tomográfica. Com isso, o algoritmo aplicado usando essa técnica foi estabelecido com base no pseudocódigo 6 (Apêndice A).

4.2.4.3 Segmentação utilizando a técnica de Grafos

A terceira técnica de segmentação avaliada nesse trabalho utilizou o conceito da teoria dos grafos para a segmentação das fatias tomográficas. O procedimento utilizado para a construção dessa técnica foi iniciado com o uso da fatia tomográfica que foi previamente filtrada, logo após, foi realizado a equalização do histograma para que o contraste da fatia tomográfica fosse realçado. Assim, com a fatia tomográfica equalizada, foi iniciado o processo da construção de um grafo ponderado não dirigido sobre a fatia tomográfica. Neste contexto, são representados os vértices do grafo pelos *pixels* da fatia tomográfica. As arestas são representadas pela conexão

entre dois vértices. Todo o processo utilizado nessa técnica pode ser visualizado com base no pseudocódigo 7 (Apêndice A).

Conforme pode ser observado, o procedimento aplicado para realizar a segmentação em grafo foi iniciado a partir da linha 50 representada no pseudocódigo 7 (Apêndice A), onde a fatia tomográfica filtrada obtida na etapa anterior foi utilizada. Nesse referido pseudocódigo, também foi possível observar a aplicação do método de Edmonds-Karp, o qual foi utilizado para a obtenção do fluxo máximo ou para o corte mínimo do grafo (EDMONDS; KARP, 1972).

O algoritmo de Edmonds-Karp é semelhante ao método de Ford-Fulkerson para resolver os problemas de fluxo máximo ou de corte mínimo em um grafo ponderado (LAMMICH; SEFIDGAR, 2016). Desse modo, sua implementação pode ser encontrada em trabalhos de Mekkittikul e McKeown (1998) e Lammich e Sefidgar (2016). Esta técnica é iniciada primeiramente com a criação de um grafo ponderado e orientado, contendo o vértice de início s e o vértice t como vértice final do fluxo. Logo, a partir do vértice s do grafo, os fluxos são enviados para o vértice t até que não haja arestas saturadas. Para a implementação dessa técnica neste trabalho, foi realizado utilizando a biblioteca *NetworkX*² pertencente à biblioteca da linguagem Python³ para a criação e a manipulação de redes complexas.

De forma complementar, o algoritmo de busca em largura utilizado pelo método de EdmondsKarp percorreu todos os vértices adjacentes do grafo que contém a menor capacidade entre dois vértices. Entretanto, a cada iteração executada pelo método de busca, a aresta com o menor valor presente no grafo passa a ser saturada. Sendo assim, o método de Edmonds-Karp retorna o custo obtido pelo fluxo máximo e pelo dicionário contendo o particionamento das vértices resultantes.

Equalização do histograma da fatia tomográfica

Na equalização do histograma da fatia tomográfica, a mesma foi aplicada após a fatia tomográfica ter sido filtrada. Dessa forma, o processo de equalização consiste em redistribuir uniformemente a intensidade do histograma da fatia tomográfica filtrada de forma a enfatizar o melhor contraste da fatia tomográfica.

Definição dos vértices virtuais referente à semente do objeto e à semente do fundo da fatia tomográfica (conjunto de *pixels* referenciados para a análise supervisionada)

Após o término do processo de equalização do histograma, é iniciada a definição das regiões referentes ao vértice virtual da semente objeto e da semente fundo da fatia tomográfica. Este processo é realizado a partir da escolha de duas regiões da fatia tomográfica, os quais foram feitos mediante à escolha empírica de seus *pixels* centrais. Essas duas regiões devem conter *pixels* do objeto e do fundo. Em seguida, foram realizados os cálculos para cada uma dessas regiões estabelecidas, sendo que, no final, as regiões passaram a ter um valor de intensidade

² <https://networkx.github.io/documentation/networkx-1.10>

³ <https://www.python.org/about>

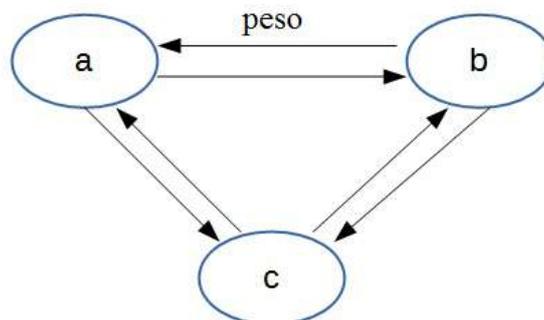
único. Contudo, os pseudocódigos 8 e 9 (Apêndice A) foram utilizados para a representação desses cálculos.

Criação do grafo e atribuição do peso a cada aresta

O processo de representar a fatia tomográfica em um grafo foi feito por meio de um grafo direcionado $G = (V, E)$, onde cada *pixel* da fatia tomográfica foi tratado como um vértice $v \in V$, assim como cada aresta presente recebeu um valor referente à capacidade (peso) que representou a similaridade entre a conexão de dois vértices. O pseudocódigo 10 (Apêndice A) representa o algoritmo dessa tarefa.

No pseudocódigo 10 (Apêndice A), o número 255 refere-se ao maior valor de intensidade de um *pixel* da fatia tomográfica menos a similaridade absoluta entre dois vértices. Nesse caso, quanto menor for o valor da aresta que estiver vinculada ao vértice, maior será a similaridade entre os dois vértices. Sendo assim, o valor de capacidade da aresta com os vértices (u, v) é sempre igual à capacidade da aresta com os vértices (v, u) , conforme ilustra a Figura 24.

Figura 24 – Procedimento realizado para o método de segmentação baseado no uso da técnica em grafos (Fonte: Adaptado de Gross e Yellen (2005)).



Além disso, as duas regiões que foram definidas nos pseudocódigos 8 e 9, da etapa anterior, foram inseridas no grafo da fatia tomográfica sob a análise dos dois vértices virtuais chamados s (inicial) e t (terminal). Nesse contexto, o vértice s é tomado como modelo de vértice de interesse, pois ele contém suas características (propriedades) referentes aos objetos. Desse modo, o vértice virtual s passa a ser conectado a todos os vértices correspondentes aos *pixels* da fatia tomográfica. Por outro lado, o vértice virtual t , representando o modelo de vértice pertencendo à região fundo, carrega característica (propriedade) referente à região do fundo da fatia tomográfica sob análise. Deste modo, a capacidade das arestas que conectam os vértices s e t com o grafo pertencente à fatia tomográfica é calculada conforme o pseudocódigo 11 (Apêndice A).

Conforme pode ser observado, no pseudocódigo 11 (Apêndice A), I_p representa o valor de intensidade do vértice (*pixel*) no ponto p do grafo, enquanto que u_r representa o valor da intensidade média da região associada ao objeto ou ao fundo, isto é, se for considerado o vértice

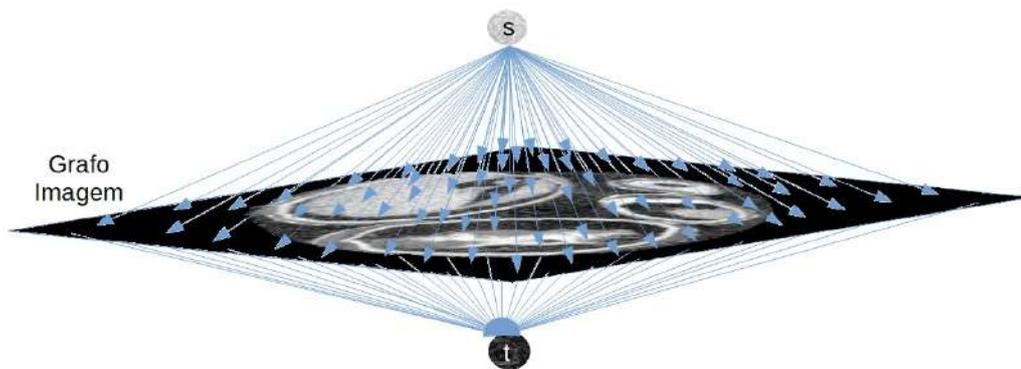
s ou t respectivamente. Como último parâmetro a ser avaliado, foi observado o σ_2 , o qual representa a variância da região associada ao objeto ou ao fundo.

Conexão de cada aresta ao grafo

As conexões entre os vértices no grafo são realizadas entre seus vértices adjacentes, os quais são pertencentes aos eixos verticais e horizontais da fatia tomográfica sob análise, sendo o seu estabelecimento realizado no algoritmo, conforme o pseudocódigo 12 (Apêndice A).

A Figura 25 ilustra esquematicamente a representação que trata da conexão entre os vértices de um grafo obtida para uma fatia tomográfica sob análise.

Figura 25 – Procedimento realizado para o método de segmentação em grafos (Fonte: Elaborado pelo autor).



Montagem da fatia tomográfica obtida pelo método de Edmonds-Karp

Após encontrar o fluxo máximo do grafo, por meio do método de Edmonds-Karp, deve ser aplicado um algoritmo de busca conforme o pseudocódigo 13 (Apêndice A), onde a partir do vértice s do dicionário. Sendo assim, os vértices que foram alcançados pela busca da partição em s , ou seja, os *pixels* pertencem e se assemelham ao objeto. Os vértices não alcançados pela busca são associados à região do fundo da fatia tomográfica. Com isso, foi criada uma matriz do tamanho da fatia tomográfica segmentada com o valor de intensidade 1 para que cada vértice retornado pela busca de s seja inserido na matriz com valor 0.

4.2.5 Extração de Características

A partir das regiões de interesse, estabelecidas com as técnicas citadas, foram também avaliados os usos dos descritores HOG e daqueles que são introduzidos pelos momentos invariantes de Hu para detectarem e extraírem as características das fatias tomográficas de sementes agrícolas oleaginosas. Para cada uma dessas técnicas, os algoritmos foram implementados utilizando a linguagem Python com a biblioteca OpenCV⁴.

⁴ OpenCV:<<https://opencv.org/about.html>>

Os pseudocódigos 14 e 15 (Apêndice A) foram organizados e utilizados para a extração de características baseando-se nas técnicas de HOG e nos momentos invariantes de Hu, respectivamente.

Os valores atribuídos aos parâmetros da técnica HOG foram descritos na forma:

- *winSize*: significa o tamanho da janela para detecção. Nesse caso, o valor do tamanho definido para esse parâmetro foi igual ao tamanho da fatia tomográfica segmentada.
- *blockSize*: significa o tamanho do bloco em *pixels* aplicado sobre a fatia tomográfica. Nesse contexto, esse parâmetro também tratou da variação de luminância da fatia tomográfica.
- *blockStride*: refere-se à sobreposição sobre a fatia tomográfica entre os blocos vizinhos.
- *cellSize*: significa o tamanho da célula aplicada sobre a fatia tomográfica. Nesse contexto, quando o valor atribuído para esse parâmetro é um número pequeno, o vetor de características se torna grande e com informações não relevantes para a classificação.
- *nbins*: significa o número de gradientes contidos no vetor de histograma.

Conforme foi descrito pelo pseudocódigo 15 (Apêndice A), para o cálculo dos momentos invariantes de Hu, os parâmetros p e q referiram-se à ordem dos momentos. Entretanto, antes de calcular os momentos invariantes de Hu, primeiramente, foi necessário o cálculo dos momentos bidimensionais, dos momentos centrais e dos momentos centrais normalizados, pois cada um dos momentos invariantes de Hu dependeram dos cálculos desses momentos mencionados.

4.2.6 Estabelecimento do algoritmo para Análise de Componentes Principais

A modelagem aplicada pela Análise de Componentes Principais (PCA) é empregada neste trabalho para reduzir a dimensionalidade dos vetores de características. Assim sendo, foram agrupadas em um único vetor de características contendo os resultados obtidos pelos métodos HOG e pelos momentos invariantes de Hu. Deste modo, uma representatividade de um vetor de dados aumentados foi aplicada à análise de componentes principais para extrair somente informações necessárias e para evitar redundância. Posto isso, utilizando a biblioteca Scikit-learn⁵ foi aplicada a técnica PCA conforme ilustra o pseudocódigo 16 (Apêndice A).

4.2.7 Classificação de Padrões

Para o estabelecimento do método de classificação das sementes oleaginosas foram avaliados os métodos de classificação supervisionada SVM e Naïve Bayes. Os pseudocódigos 17 e 18

⁵ <https://scikit-learn.org/stable/modules/generated/sklearn.decomposition.PCA.html>

(Apêndice A), ilustram a estruturação dos algoritmos que foram organizados e implementados tendo como base os conceitos estabelecidos nessas técnicas.

Com os resultados obtidos pela técnica de PCA da etapa anterior, na próxima etapa foi realizado a separação do conjunto de dados entre o treinamento e o teste. Na etapa de treinamento, o classificador recebeu um conjunto de dados para que se tenha um entendimento das características que contiveram cada classe. Logo após, na etapa do teste, o classificador identificou cada padrão presente nas fatias tomográficas de sementes agrícolas oleaginosas sob análises. Para a implementação da técnica de classificação baseada em SVM foi utilizada a biblioteca Scikit-learn⁶. Da mesma forma, o algoritmo de classificação Naïve Bayes foi organizado e implementado utilizando a mesma biblioteca acima referenciada, entretanto, devendo observar que com a obtenção do resultado se fez necessário considerar a probabilidade *a priori* de um conjunto de padrões de fatias tomográficas de sementes agrícolas oleaginosas pertencentes à classe de sementes com defeitos ou à classe de sementes sem defeitos.

4.3 Considerações Finais

Neste Capítulo foram apresentados os materiais e o detalhamento das técnicas do processamento de imagens e da visão computacional para a construção do método que classificou as sementes oleaginosas e os seus algoritmos. Neste contexto, foram consideradas também a utilização de técnicas PCA e dois tipos de classificadores, sendo eles de características probabilística e determinística, Naive Bayes e SVM, respectivamente. No Capítulo seguinte, serão apresentados os resultados e as discussões dos ensaios tomográficos das sementes agrícolas oleaginosas, bem como a avaliação das técnicas de processamento de imagens e da visão computacional, as quais foram pré selecionadas com base na literatura em estado da arte.

⁶ <https://scikit-learn.org>

Capítulo 5

RESULTADOS E DISCUSSÕES

Neste Capítulo são apresentados os resultados dos vários ensaios realizados considerando as fatias tomográficas dos ensaios feitos com as amostras de sementes agrícolas de girassol, de pinhão-manso e de soja. Também, são abordadas as avaliações das diversas técnicas do processamento das imagens tomográficas para a composição do método de classificação dessas sementes oleaginosas. Adicionalmente, são expostas as discussões sobre os resultados obtidos considerando o uso das métricas PSNR, MSE, SSIM e DSC, incluindo também as análises estatísticas baseadas no uso de boxplot. Finalmente, são demonstradas as avaliações dos classificadores tendo como base os resultados obtidos nas matrizes de confusão que foram obtidas.

5.1 Resultados de Análises das Modalidades de Filtragem das Fatias Tomográficas na Etapa de Pré-Processamento

Nesta seção são apresentados os resultados obtidos com as técnicas de filtragem de difusão anisotrópica, de *non-local means*, do Gaussiano e de passa-banda ideal das fatias tomográficas obtidas para sementes agrícolas oleaginosas. Neste contexto, as fatias tomográficas passaram por um processo de adição de ruído do tipo Gaussiano para as análises da qualidade dos filtros, tendo em vista que as fatias tomográficas foram obtidas utilizando a tomografia de raios-X.

O primeiro filtro utilizado nesta etapa de análise é o de difusão anisotrópica. Sendo assim, os parâmetros utilizados para esse processo de filtragem se encontram descritos na Tabela 2.

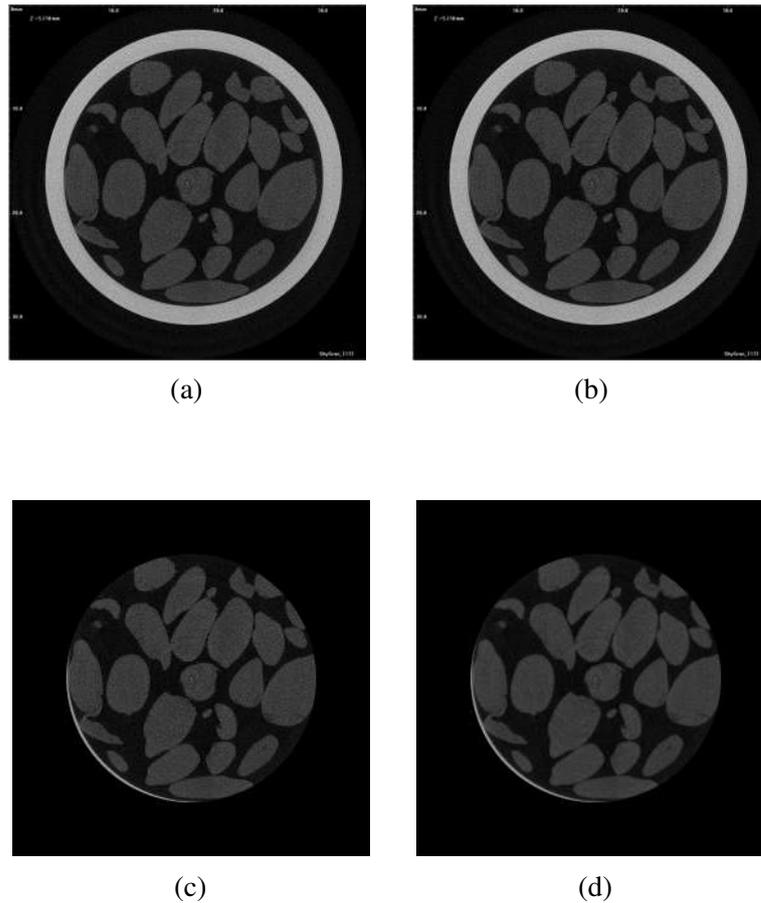
Tabela 2 – Valores aplicados para cada parâmetro do filtro de difusão anisotrópica.

Parâmetro	Valor
κ	90
Γ	0,15
NumIterações	40

O resultado final da avaliação do filtro de difusão anisotrópica foi obtido com a execu-

ção do pseudocódigo 1 gerando uma fatia tomográfica suavizada com as bordas preservadas, conforme ilustrado na Figura 26. Exemplos desses resultados se encontram apresentados no Apêndice B.

Figura 26 – Exemplo do resultado da aplicação do filtro de difusão anisotrópica aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (26a), à fatia tomográfica após adição de ruído Gaussiano (26b), ao ROI da fatia tomográfica ruidosa (26c) e à fatia tomográfica após a aplicação do filtro (26d).



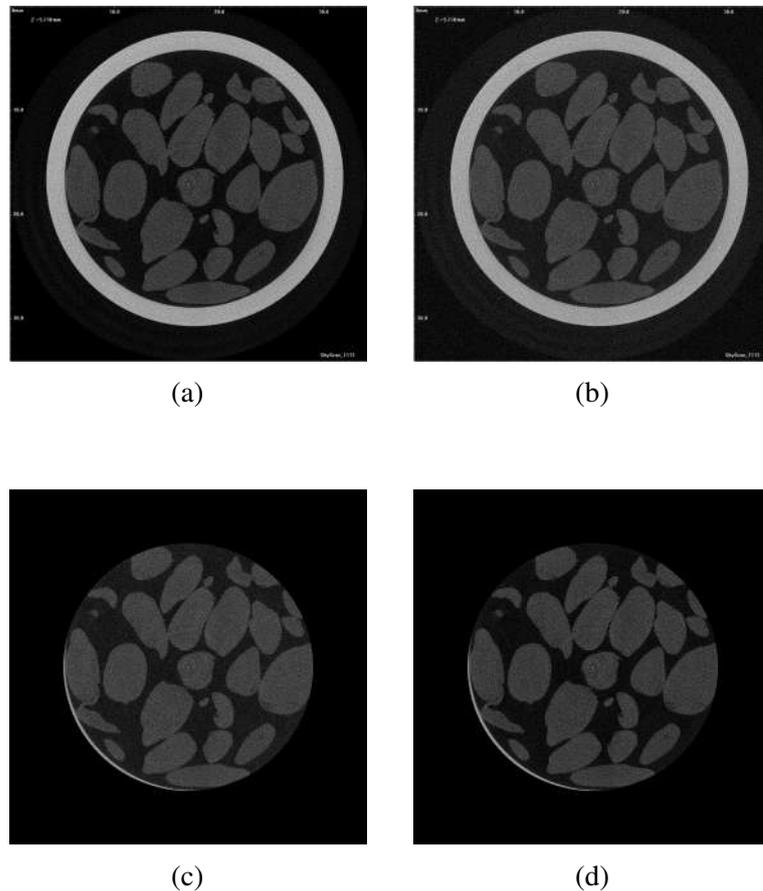
O segundo filtro utilizado nesta etapa de análise é o filtro *non-local means*. Sendo assim, os parâmetros utilizados para esse processo de filtragem se encontram descritos na Tabela 3.

Tabela 3 – Valores aplicados para cada parâmetro do filtro *non-local means*.

Parâmetro	Valor
tamanho <i>patche</i>	7
distância <i>patche</i>	21

O resultado final da avaliação do filtro *non-local means* foi obtido com a execução do pseudocódigo 4, considerando o tamanho e a distância do *patche*, o que resultou em fatias tomográficas suavizadas, conforme ilustrado na Figura 27. Exemplos desses resultados se encontram apresentados no Apêndice B.

Figura 27 – Exemplo do resultado da aplicação do filtro *non-local means* aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (27a), à fatia tomográfica após adição de ruído Gaussiano (27b), ao ROI da fatia tomográfica ruidosa (27c) e à fatia tomográfica após a aplicação do filtro (27d).



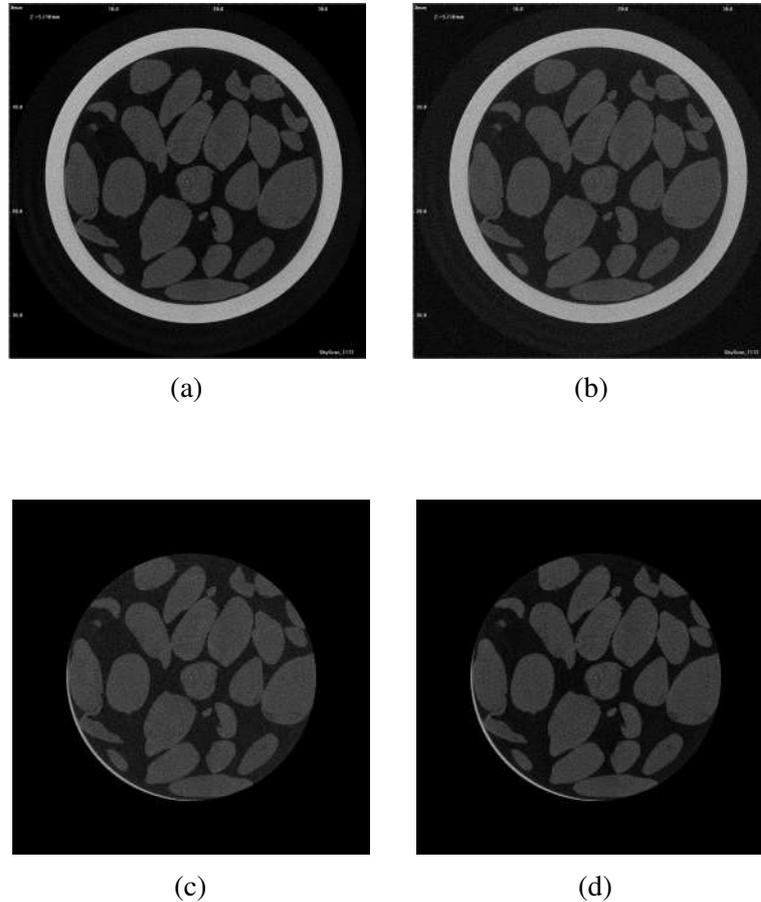
A terceira filtragem utilizada nesta etapa de análise é baseada na aplicação do filtro Gaussiano. A Tabela 4 ilustra os parâmetros utilizados para este processo de filtragem.

Tabela 4 – Valores aplicados para cada parâmetro do filtro Gaussiano.

Parâmetro	Valor
tamanho <i>kernel</i>	(5,5)

O resultado final do filtro Gaussiano foi obtido com a execução do pseudocódigo 3, ilustrado pela Figura 28, por uma fatia tomográfica suavizada com a eliminação de altas frequências provocando perdas nas informações de bordas. Exemplos desses resultados se encontram apresentados no Apêndice B.

Figura 28 – Exemplo do resultado da aplicação do filtro Gaussiano aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (28a), à fatia tomográfica após adição de ruído Gaussiano (28b), ao ROI da fatia tomográfica ruidosa (28c) e à fatia tomográfica após a aplicação do filtro (28d).

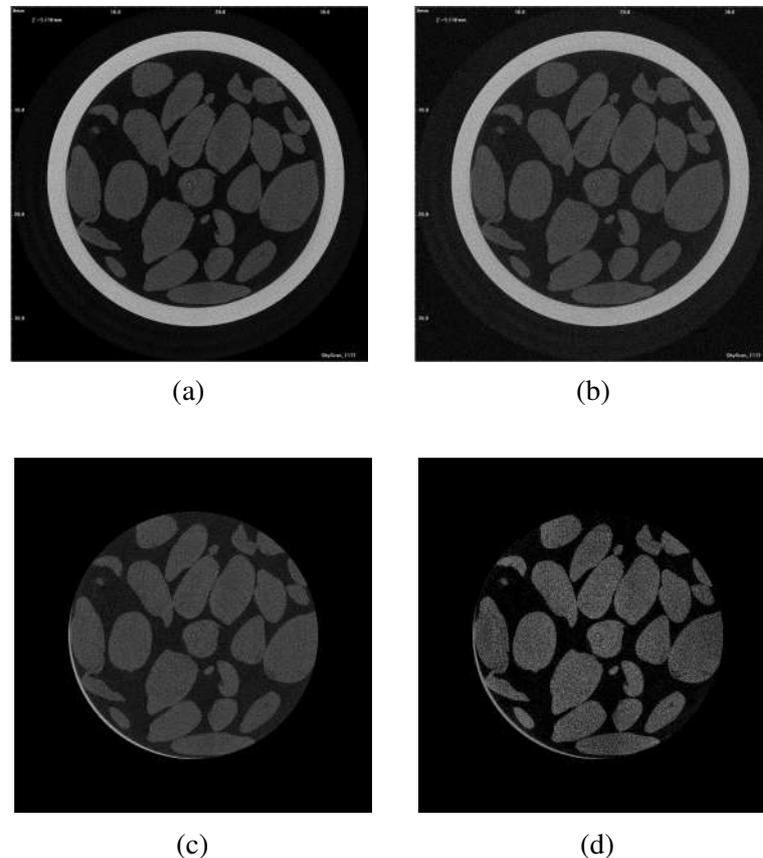


O quarto filtro utilizado nesta etapa de análise é o passa-banda ideal cujo resultado apresenta uma suavização da fatia tomográfica e o borramento das bordas nas fatias tomográficas das sementes analisadas.

O resultado final avaliado para essa modalidade de filtro, passa-banda ideal, foi executado pelo pseudocódigo 2 com a devida adequação dessa modalidade de filtro conforme foi ilustrado na Figura 29. Exemplos desses resultados se encontram apresentados no Apêndice B.

Deste modo, a qualidade das fatias tomográficas decorrentes da aplicação dos filtros é avaliada no conjunto das bases de fatias tomográficas utilizando as métricas MSE, PSNR e SSIM. Nesse contexto, o MSE possibilitou calcular o erro médio quadrático da diferença entre os valores de *pixels* da fatia tomográfica de referência e da sua fatia tomográfica filtrada. O resultado desse índice comparando as duas fatias tomográficas se aproximou do valor 0, isso indica que há maior similaridade entre as duas fatias tomográficas.

Figura 29 – Exemplo do resultado da aplicação do filtro passa-banda ideal aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de girassol (29a), à fatia tomográfica após adição de ruído Gaussiano (29b), ao ROI da fatia tomográfica ruidosa (29c) e à fatia tomográfica após a aplicação do filtro (29d).



Em relação à aplicação da métrica PSNR, foi possível avaliar o pico máximo na relação Sinal/Ruído entre uma fatia tomográfica de referência e sua fatia tomográfica filtrada. Quanto maior for o valor resultante desse índice, melhor será o resultado do filtro aplicado.

Adicionalmente, a aplicação da métrica SSIM possibilitou avaliar a semelhança estrutural entre uma fatia tomográfica de referência e sua fatia tomográfica filtrada a partir dos elementos de média, de covariância e de variância. Sendo assim, quanto maior for o valor resultante desse índice, melhor será o resultado do filtro aplicado.

As Figuras 30, 31, 32, 33, 34, 35, 36, 37 e 38 apresentam respectivamente as avaliações realizadas utilizando a ferramenta estatística boxplot para as métricas MSE, PSNR e SSIM para 812 fatias tomográficas das sementes de girassol, de pinhão-mansão, de soja e de imagem composta, considerando para cada um dos filtros de difusão anisotrópica, o *non-local means*, o Gaussiano e o passa-banda ideal.

Figura 30 – Resultados obtidos pela métrica MSE ao aplicar em fatias tomográficas de sementes de girassol após a adição do ruído Gaussiano.

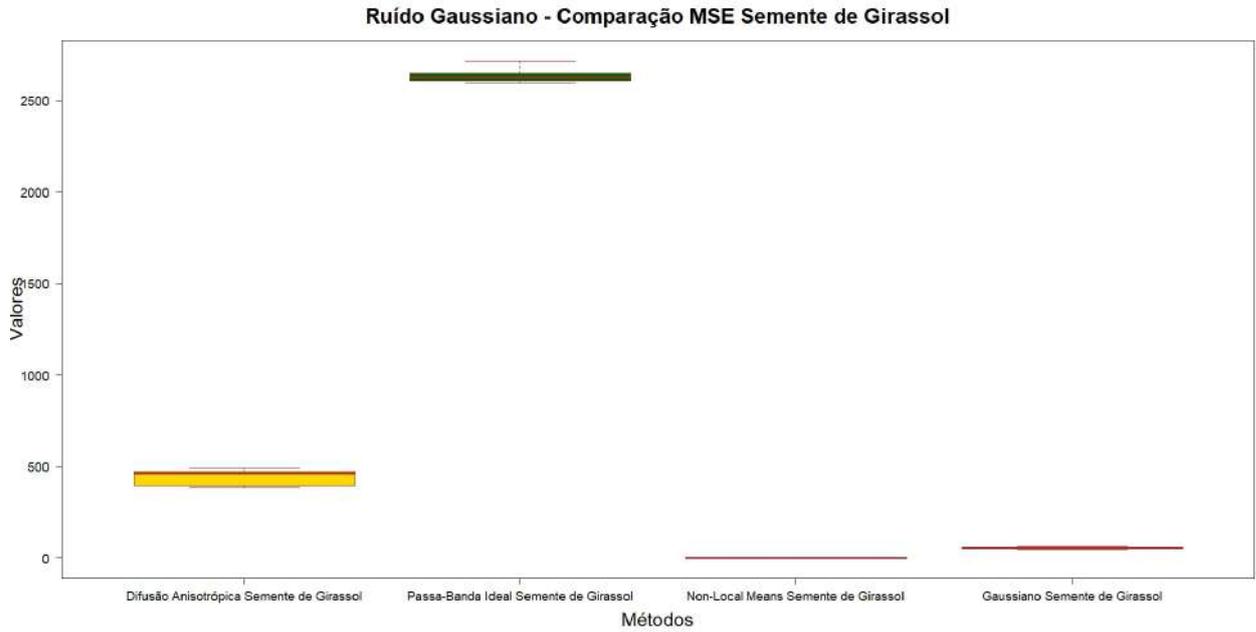


Figura 31 – Resultados obtidos pela métrica PSNR ao aplicar em fatias tomográficas de sementes de girassol após a adição do ruído Gaussiano.

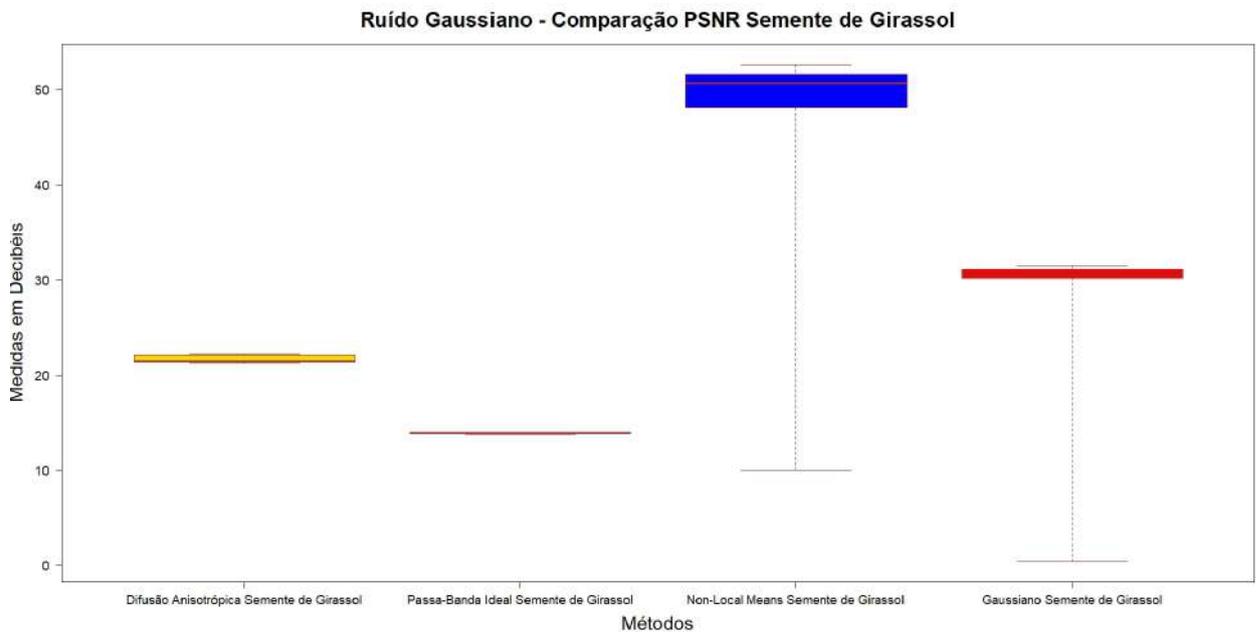


Figura 32 – Resultados obtidos pela métrica SSIM ao aplicar em fatias tomográficas de sementes de girassol após a adição do ruído Gaussiano.

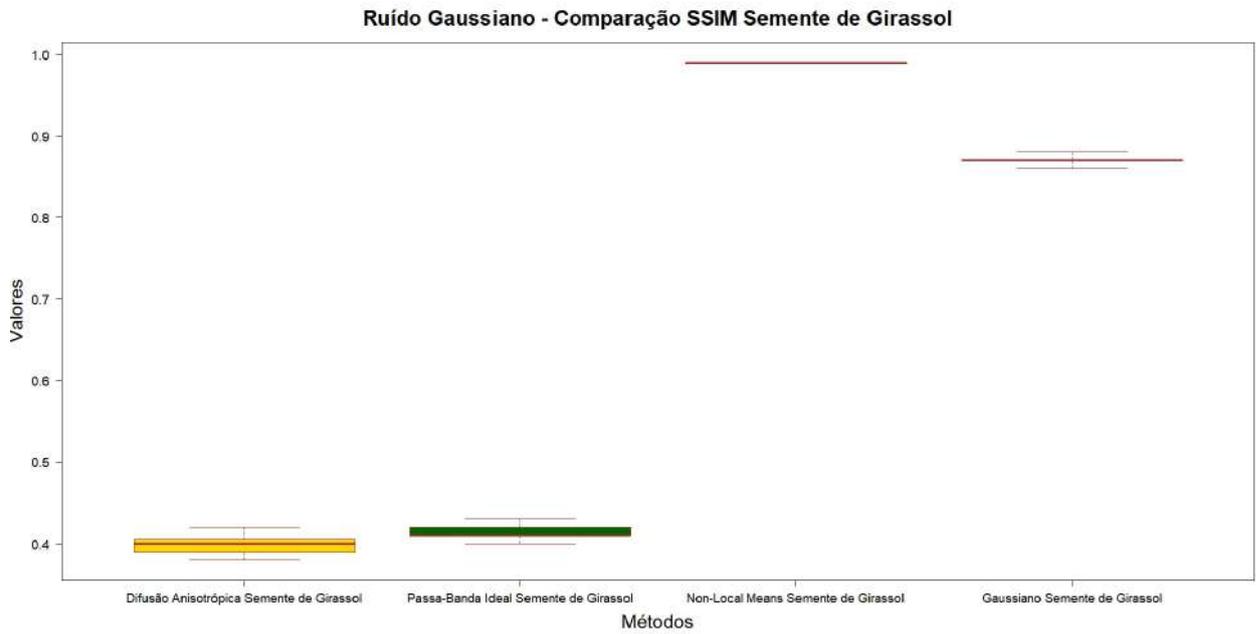


Figura 33 – Resultados obtidos pela métrica MSE ao aplicar em fatias tomográficas de sementes de pinhão-manso após a adição do ruído Gaussiano.

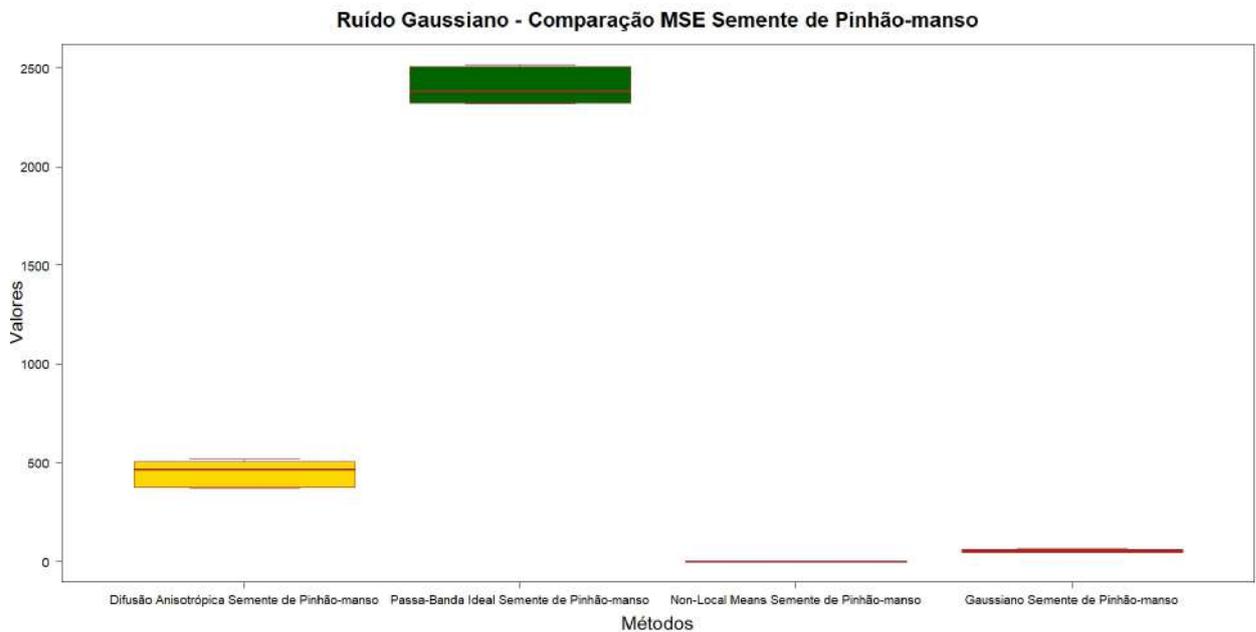


Figura 34 – Resultados obtidos pela métrica PSNR ao aplicar em fatias tomográficas de sementes de pinhão-manso após a adição do ruído Gaussiano.

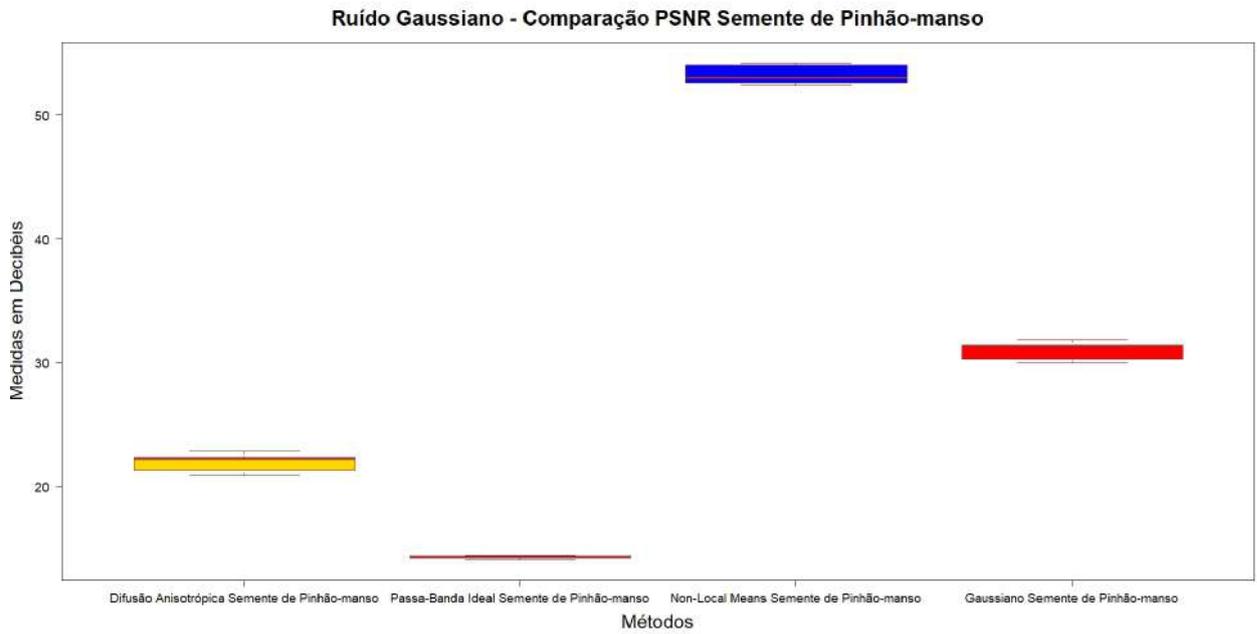


Figura 35 – Resultados obtidos pela métrica SSIM ao aplicar em fatias tomográficas de sementes de pinhão-manso após a adição do ruído Gaussiano.

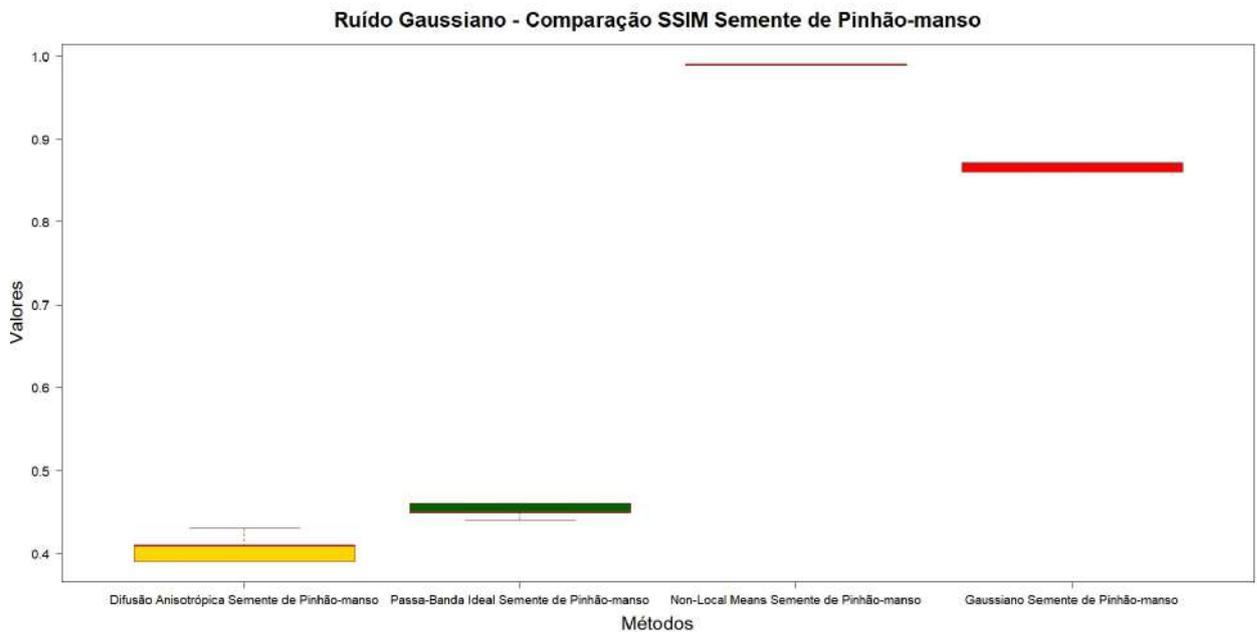


Figura 36 – Resultados obtidos pela métrica MSE ao aplicar em fatias tomográficas de sementes de soja após a adição do ruído Gaussiano.

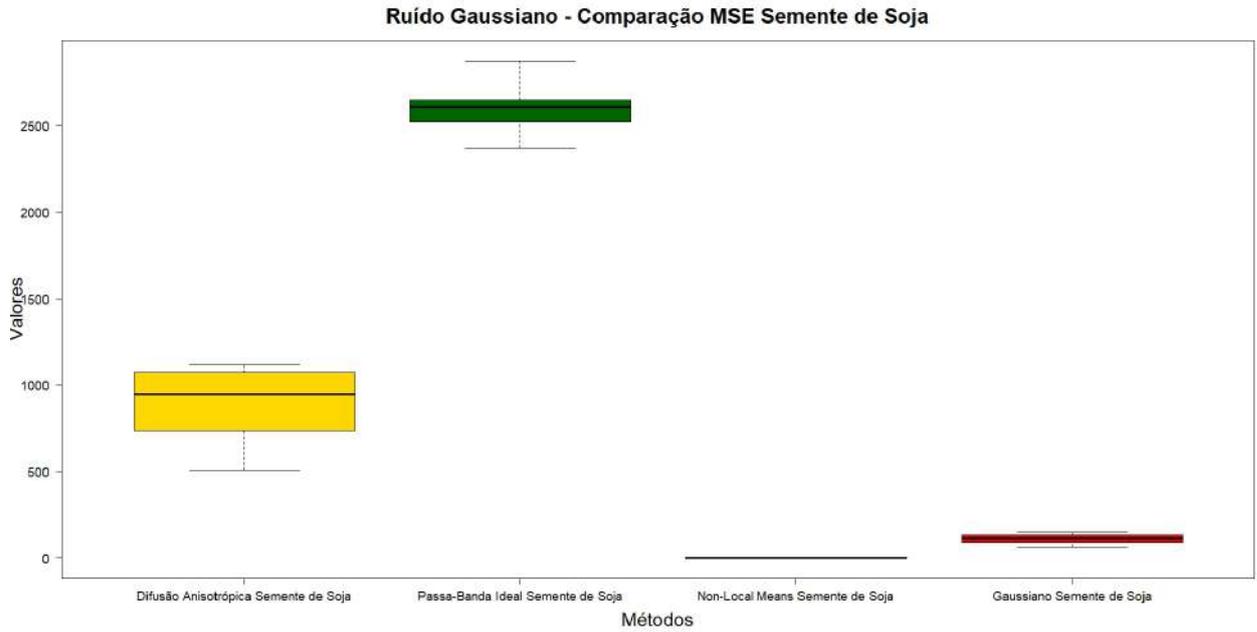


Figura 37 – Resultados obtidos pela métrica PSNR ao aplicar em fatias tomográficas de sementes de soja após a adição do ruído Gaussiano.

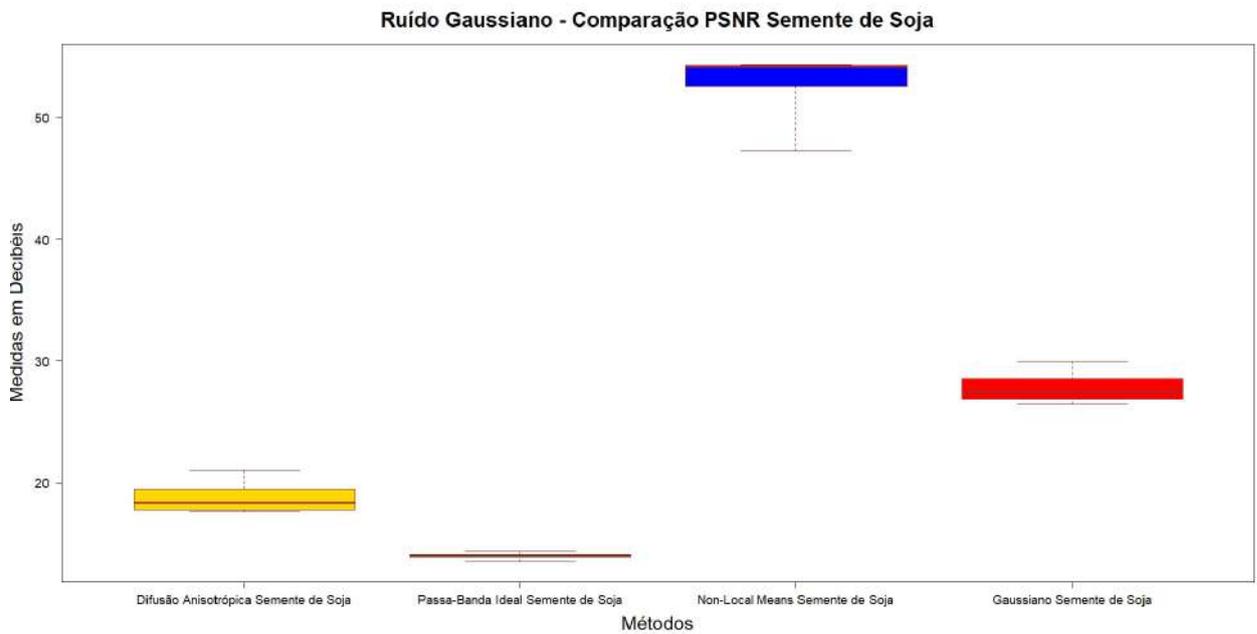
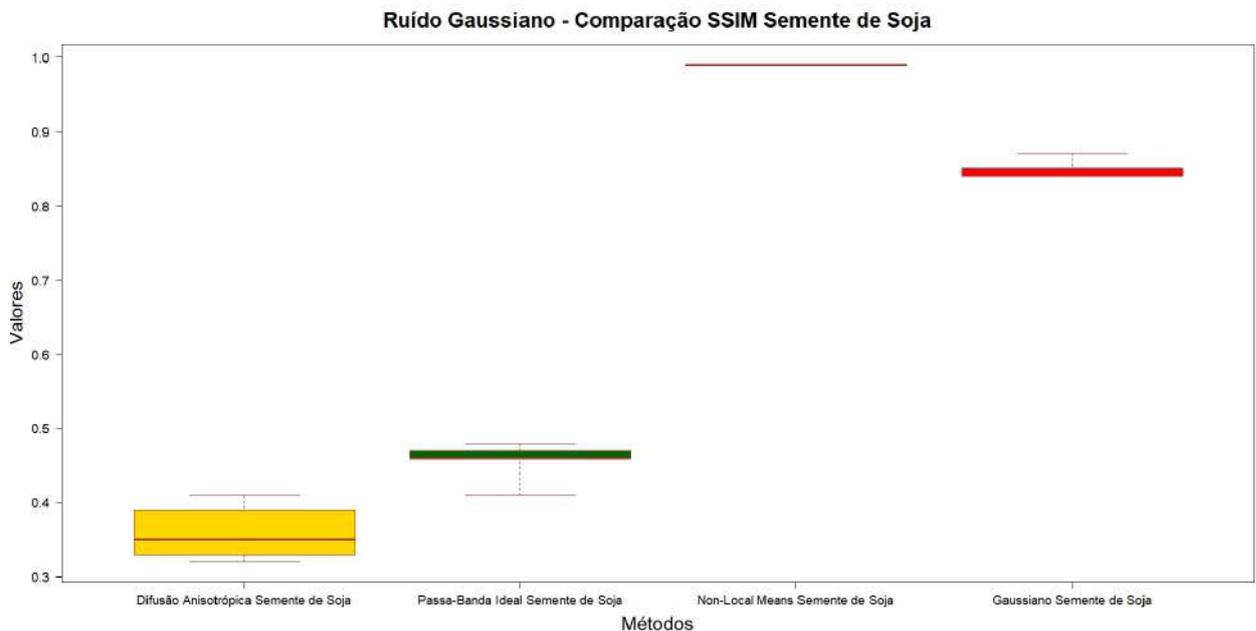


Figura 38 – Resultados obtidos pela métrica SSIM ao aplicar em fatias tomográficas de sementes de soja após a adição do ruído Gaussiano.



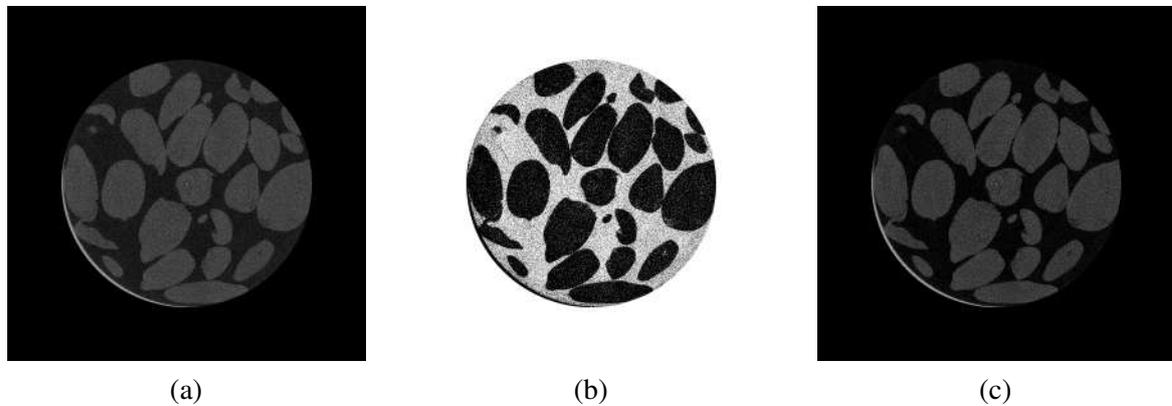
Analisando os resultados apresentados com base no uso da ferramenta estatística boxplot (Figuras 30, 31, 32, 33, 34, 35, 36, 36, 37 e 38) é possível observar que tanto para as métricas MSE e PSNR quanto para métrica SSIM, que o filtro *non-local means* apresentou o melhor resultado quando foi aplicação o ruído Gaussiano.

5.2 Análises das Técnicas de Segmentação

Nesta seção são apresentados os resultados obtidos na etapa de segmentação e na métrica DSC utilizadas para avaliarem a estrutura das fatias tomográficas de sementes agrícolas oleaginosas após a aplicação de cada técnica executada. As técnicas de segmentação avaliadas neste trabalho são Limiarização, Otsu e Grafo.

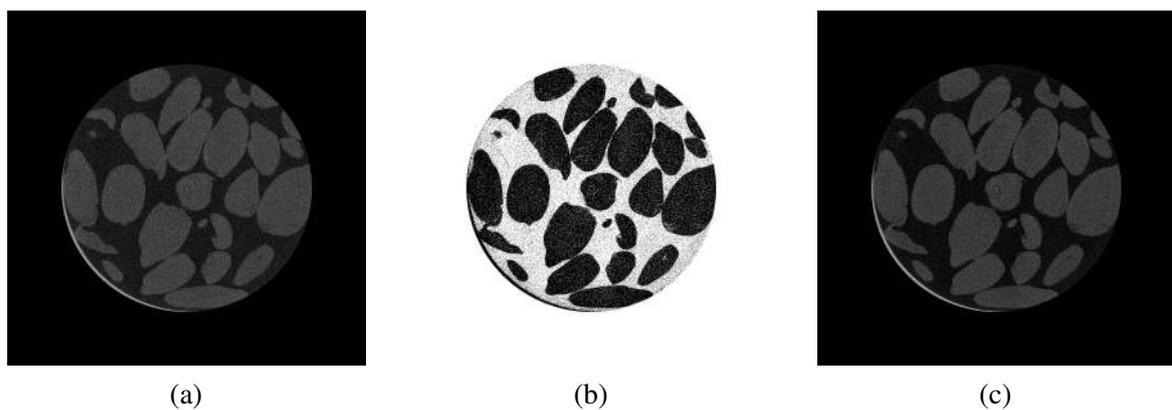
O resultado obtido executado pela técnica de limiarização originou a obtenção de uma fatia tomográfica binária representando o objeto pela cor preta e o fundo pela cor branca, conforme foi ilustrado na Figura 39. Exemplos de resultados com a utilização das técnicas de segmentação por meio da técnica de limiarização podem ser apresentados no Apêndice B.

Figura 39 – Exemplo de segmentação pela técnica de limiarização aplicada em fatia tomográfica após o filtro Gaussiano referente à semente de girassol (39a), à fatia tomográfica binarizada da técnica de segmentação (39b) e à conjunção entre as duas fatias tomográficas (39c).



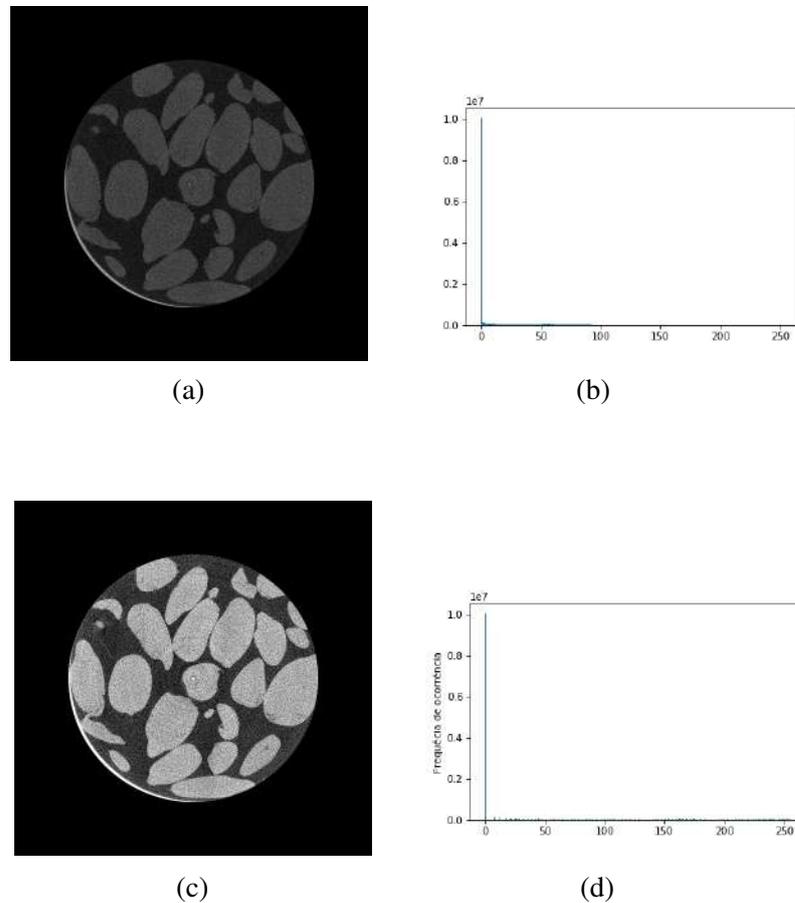
O resultado obtido pela técnica de Otsu também deu origem a uma fatia tomográfica binária onde o objeto se localizou pela cor preta e o fundo pela cor branca, conforme foi ilustrado na Figura 40. Exemplos da aplicação da técnica de segmentação por meio da técnica de Otsu podem ser apresentados no Apêndice B.

Figura 40 – Exemplo de segmentação pela técnica de Otsu aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de girassol (40a), à fatia tomográfica binarizada da técnica de segmentação (40b) e à conjunção entre as duas fatias tomográficas (40c).



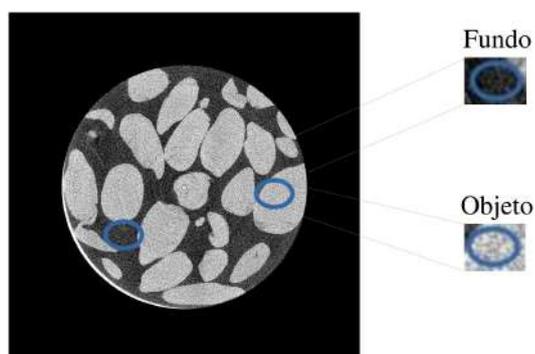
Diferentemente das técnicas de segmentação de limiarização e Otsu, a técnica em grafos foi iniciada com o processo de equalização do histograma, conforme foi ilustrado na Figura 41 ou apresentado no Apêndice B.

Figura 41 – Exemplo de processo de equalização do histograma a partir da fatia tomográfica de girassol suavizada com o filtro Gaussiano (41a) e o seu histograma (41b), juntamente com o resultado da fatia tomográfica equalizada (41c) e o seu histograma (41d).



Logo após, foram utilizados os pseudocódigos 8 e 9 que definiram os vértices virtuais referentes à semente do objeto e à semente do fundo (neste caso, a semente representa um conjunto de *pixels*), conforme ilustrado na Figura 42.

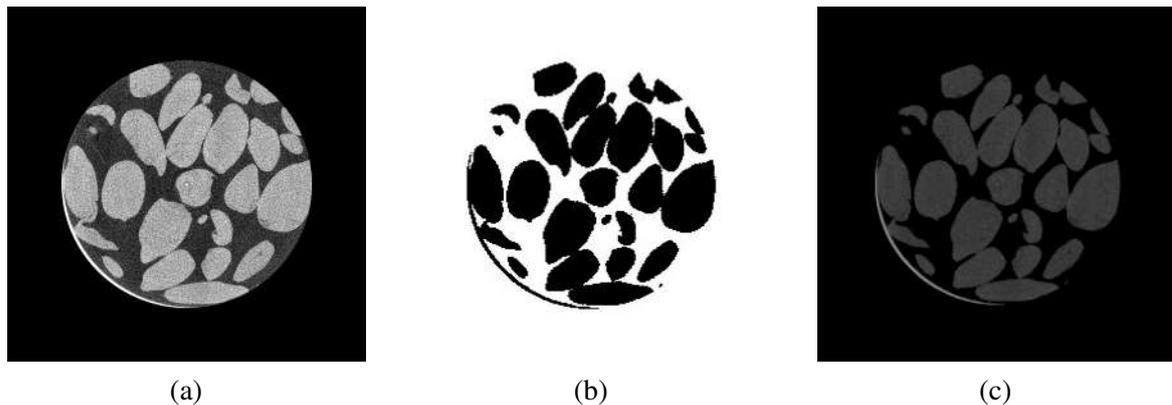
Figura 42 – Exemplo de processo feito pela técnica de segmentação em grafo aplicado para a escolha da região pertencente ao vértice virtual objeto e ao vértice virtual fundo referentes à cultura de girassol.



Após os passos anteriores serem executados, o resultado da segmentação por grafos, o

resultado obtido e o exemplo de fatia tomográfica segmentada com essa técnica, eles podem ser vistos na Figura 43 ou apresentado no Apêndice B.

Figura 43 – Exemplo de segmentação pela técnica grafo aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de girassol (43a), ao resultado da fatia tomográfica binarizada da segmentação (43b) e à conjunção entre as duas fatias tomográficas (43c).



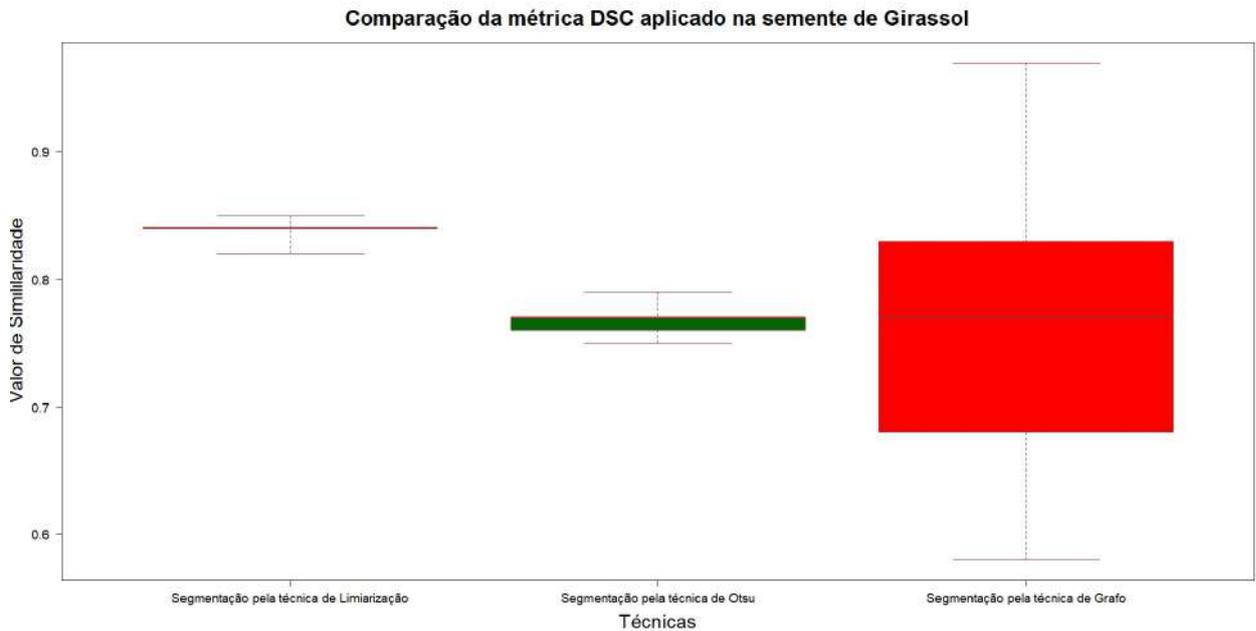
De forma a avaliar as técnicas de segmentação, considerando a aplicação das fatias tomográficas de sementes agrícolas oleaginosas, foi possível observar que as técnicas de segmentação de limiarização, de Otsu e de grafo levaram a uma segmentação conjunta de todos os tipos de sementes agrícolas oleaginosas presentes nas amostras.

5.2.1 Resultados da Avaliação das Técnicas de Segmentação Utilizando a Ferramenta Estatística Boxplot Aplicada em Todos os Conjuntos de Fatias Tomográficas

A qualidade das fatias tomográficas decorrentes das aplicações das técnicas de segmentação foram avaliadas no conjunto das bases de fatias tomográficas utilizando a métrica DSC. Deste modo, a métrica DSC avalia a similaridade entre uma fatia tomográfica de referência sobreposta a sua fatia tomográfica segmentada, a partir da sobreposição das duas máscaras binárias. Sendo assim, quando o resultado deste índice comparando duas fatias tomográficas se aproxima do valor 1, indica que há maior similaridade entre as duas fatias tomográficas.

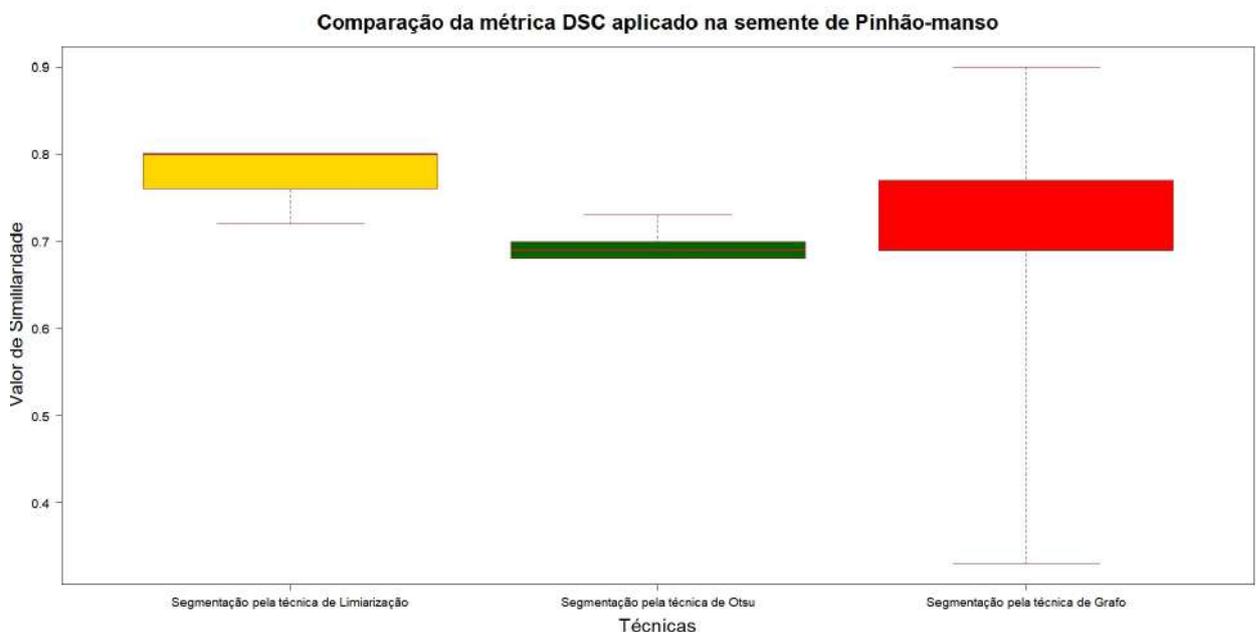
As Figuras 44, 45 e 46 apresentam, respectivamente, as avaliações realizadas pelas técnicas de segmentação por limiarização, Otsu e grafo, utilizando a ferramenta estatística boxplot e o conjunto de resultados obtidos com a avaliação da métrica DSC considerando, dessa forma, as fatias tomográficas das sementes de girassol, de pinhão-manso e de soja, respectivamente.

Figura 44 – Resultados obtidos pela métrica DSC em fatias tomográficas de sementes de girassol após a aplicação das técnicas de segmentação por limiarização, Otsu e grafo.



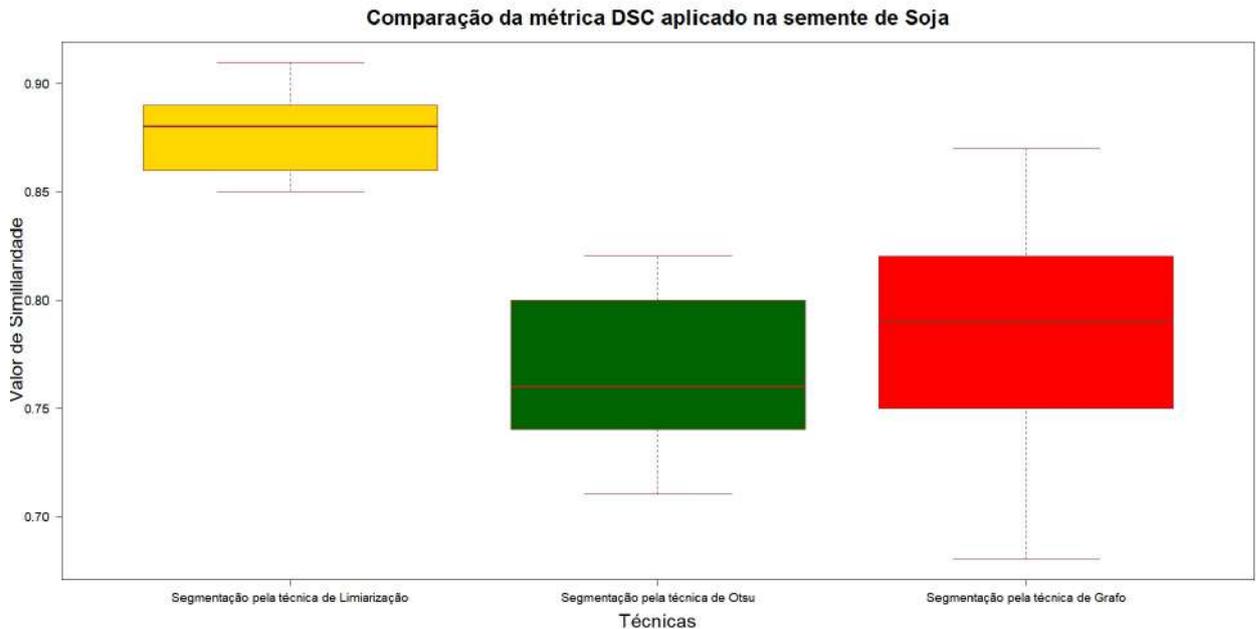
Conforme observado, o uso de segmentação por limiarização se mostrou satisfatório para as aplicações em fatias tomográficas obtidas por semente de girassol. Entretanto, também ocorreram situações onde a segmentação baseada em grafos possibilitou a obtenção de resultados que também se mostraram satisfatórios.

Figura 45 – Resultados obtidos pela métrica DSC em fatias tomográficas de sementes de pinhão-mansó após a aplicação das técnicas de segmentação por limiarização, Otsu e grafo.



O uso de segmentação por limiarização se mostrou satisfatório para as aplicações em fatias tomográficas obtidas por semente de pinhão-manso. Entretanto, também ocorreram situações onde a segmentação baseada em grafos possibilitou a obtenção de resultados confiáveis, uma vez que foi observado que o 1o quartil se aproximou da mediana das análises observadas.

Figura 46 – Resultados obtidos pela métrica DSC em fatias tomográficas de sementes de soja após a aplicação das técnicas de segmentação por limiarização, Otsu e grafo.

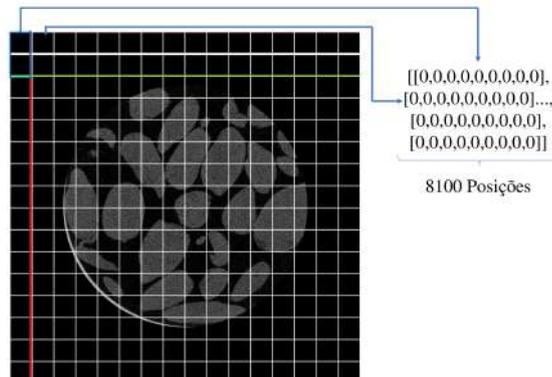


Conforme observado, o uso de segmentação por limiarização apresentou o melhor resultado para a segmentação das fatias tomográficas contendo a semente de soja.

5.2.2 Resultados das Avaliações das Técnicas de Extração de Características

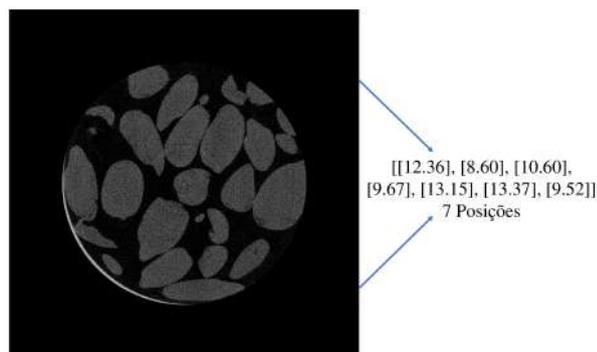
O descritor HOG, executado com base no pseudocódigo 14, foi aplicado considerando uma redução na resolução espacial das fatias tomográficas para 256×256 pixels, células de 16×16 , em blocos de 2×2 e 9 orientações em cada uma delas. Deste modo, ao final da aplicação da técnica, o seu vetor de característica passa a ser representado por 8100 posições, conforme ilustrado na Figura 47. Exemplos dessas operações podem ser apresentados no Apêndice B.

Figura 47 – Exemplo de extração de característica do método HOG aplicado em fatia tomográfica referente à semente de girassol.



Quanto aos momentos invariantes de Hu, para a avaliação dos resultados, os mesmos foram calculados baseando-se nos momentos centrais e bidimensionais das fatias tomográficas das sementes agrícolas oleaginosas sob análise. Sendo assim, esses resultados deram origem a um vetor de característica contendo 7 posições, sendo que em cada uma delas foram registrados os referidos momentos invariantes, conforme o exemplo ilustrado na Figura 48. Exemplos dessas operações podem ser apresentados no Apêndice B.

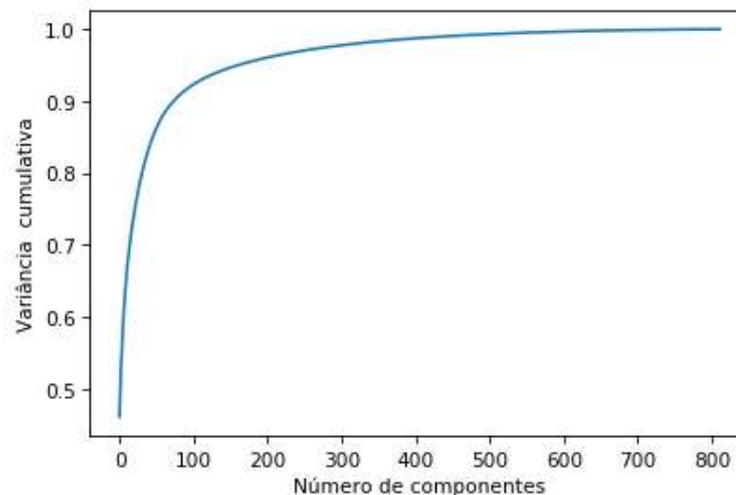
Figura 48 – Exemplo de extração de característica do método momentos invariantes de Hu aplicado na fatia tomográfica referente à semente de girassol.



Quanto a esses descritores que foram aplicados e analisados, um deles é referente à textura (HOG) e o outro referente às características geométricas das fatias tomográficas (HU). Na organização do método de análise, ambos descritores foram utilizados considerando o enriquecimento do resultado da análise. A forma encontrada para essa operação foi o uso da técnica de Análise de Componentes Principais (PCA), de forma a reduzir a dimensionalidade desses indicadores e a melhorar o desempenho do processo de análise.

Como foi observado na Figura 49, para se obter um valor aceitável de números de componentes pela técnica PCA, foi realizado o cálculo da porcentagem de variação baseado em cada componente dividido à soma acumulada da variância explicada. Sendo assim, o número ideal para se atribuir ao parâmetro relacionado ao número de componentes neste trabalho foi um valor contido em um intervalo de variância acumulativa entre 0,9 a 1. Segundo Swets (1996), a taxa ideal para se manter a variação dos dados originais para o reconhecimento é estabelecida quando o número de autovetores corresponde a 95% da variância total.

Figura 49 – Taxa de variância acumulativa PCA.



Por esta razão, neste trabalho, para obter uma variância acumulativa dos dados originais são necessário utilizar apenas 125 componentes.

5.2.3 Resultados Obtidos das Técnicas de Classificação

Os classificadores utilizados e aplicados neste trabalho estão relacionados às técnicas Naïve Bayes e SVM. Sendo assim, após a aplicação do PCA, que possibilitou a composição de descritores de textura e formas geométricas, houve a realização da organização da fase de treinamento e a separação de conjunto de amostra de fatias tomográficas para o teste de validação.

Logo abaixo, serão apresentados os dados utilizados para a realização dos experimentos. Neste sentido, os parâmetros que serão apresentados a seguir, foram obtidos de acordo com a metodologia aplicada na seção anterior.

Para os experimentos de validação dos classificadores foram utilizados os seguintes requisitos:

- Três bancos de fatias tomográficas previamente organizados referentes às sementes de girassol, de pinhão-manso e de soja, separadamente;

- Banco de fatias tomográficas previamente organizado contendo os três tipos de sementes misturadas (imagem composta);
- Três bancos de dados de fatias tomográficas contendo sementes defeituosas que apresentam trincas, vazios e quebras;
- Tamanho do vetor de características constituído com informações obtidas com a técnica HOG (8100 posições) e a técnica de momentos invariantes de HU (7 posições), totalizando 8107 posições para cada fatia tomográfica;
- Aplicação da técnica PCA nos vetores de características os levando de 8107 posições para 125 posições para cada fatia tomográfica;
- Aplicação dos classificadores Naïve Bayes e SVM, considerando a análise dos parâmetros Acurácia, Precisão, Revocação, *F1-Score* e Suporte.

5.2.4 Resultados dos Classificadores

As Tabelas 5 e 6 ilustram os resultados obtidos com o uso dos classificadores Naïve Bayes e SVM considerando as proporções percentuais de fatias tomográficas de sementes agrícolas oleaginosas com e sem defeito para o treinamento e os testes, nas proporções de 80% e 20% respectivamente.

Tabela 5 – Resultados dos experimentos aplicados para uma base de dados com 80% treinamento e 20% teste usando o classificador Naïve Bayes.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,95	0,78	0,86	23	0,82
Girassol defeituosa	1,00	0,57	0,73	28	
Pinhão-manso	0,85	0,81	0,83	21	
Pinhão-manso defeituosa	0,78	0,91	0,84	23	
Soja	0,72	0,91	0,81	23	
Soja defeituosa	0,59	0,77	0,67	22	
Imagem Composta	1,00	1,00	1,00	23	

Tabela 6 – Resultados dos experimentos aplicados para uma base de dados com 80% treinamento e 20% teste usando o classificador SVM.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,91	0,91	0,91	23	0,94
Girassol defeituosa	0,96	0,96	0,96	28	
Pinhão-manso	1,00	0,90	0,95	21	
Pinhão-manso defeituosa	1,00	0,96	0,98	23	
Soja	0,81	0,91	0,86	23	
Soja defeituosa	0,91	0,91	0,91	22	
Imagem Composta	1,00	1,00	1,00	23	

A partir dos resultados obtidos, com a avaliação dos classificadores, é possível observar que ambos classificadores apresentaram um alto valor de percentual em relação à avaliação da acurácia. Entretanto, foram significativas as variações encontradas em relação à avaliação da precisão destes classificadores para diferentes imagens tomográficas em função dos tipos de sementes avaliadas. Neste contexto, quando utilizado a relação 80% a 20%, respectivamente, relativo às imagens usadas para o treinamento e às imagens usadas para o teste, os melhores valores de precisão foram encontrados de forma que o classificador Naïve Bayes foi o mais preciso na classificação de imagens tomográficas de girassol sem defeitos, assim como ocorreram com as imagens tomográficas de sementes que apresentaram defeitos, isto é, a precisão de 95% e de 100% respectivamente. Quando analisado, para essa mesma proporção de treinamento e teste para as imagens tomográficas de sementes de pinhão-manso, foi observado que o classificador SVM foi o mais preciso, isto é, ele apresentou uma precisão de 100% tanto para a classificação de imagens sem defeitos quanto para as imagens tomográficas com defeitos. Da mesma forma, quando analisado para essa mesma proporção de treinamento e teste, para as imagens tomográficas de sementes de soja, também foi observado que o classificador SVM foi o mais preciso, isto é, apresentou uma precisão de 81% para a classificação de imagens tomográficas de semente de soja com defeitos e 91% para a classificação de imagens tomográficas de semente de soja sem defeitos.

Além dos experimentos apresentados para uma base de dados com 80% treinamento e 20% teste dos classificadores Naïve Bayes e SVM, também foram avaliadas as diferentes proporções percentuais de fatias tomográficas de sementes agrícolas com e sem defeito, considerando uma base de dados com 70% treinamento e 30% teste, 60% treinamento e 40% teste e, por fim, com 50% treinamento e 50% teste. Os resultados desses experimentos se encontram anexados no Apêndice C.

5.3 Considerações Finais

Ao longo deste Capítulo foram apresentados e discutidos os resultados obtidos utilizados no desenvolvimento do trabalho. Neste contexto, foram apresentados os resultados desenvolvidos com base em técnicas do processamento de fatias tomográficas, incluindo as etapas de aquisição tomográfica, as técnicas do pré-processamento, a segmentação das regiões de interesse, a extração de características e a análise dos componentes principais. Adicionalmente, foram apresentados os resultados de precisão e a acurácia obtidos com o uso dos classificadores SVM e Naïve Bayes. No Capítulo seguinte será apresentada a conclusão final incluindo as principais contribuições e sugestões para os trabalhos futuros.

Capítulo 6

CONCLUSÃO

Este Capítulo apresenta as conclusões decorrentes do atendimento aos objetivos específicos e ao objetivo geral para o estabelecimento do método de classificação de sementes agrícolas oleaginosas para o plantio utilizando técnicas de processamento e visualização de imagens.

6.1 Atendimento aos Objetivos Específicos e ao Objetivo Geral

Este trabalho viabilizou o desenvolvimento e a organização de um método para a classificação de sementes agrícolas oleaginosas de boa qualidade e defeituosas, a partir do ensaio de conjuntos de amostras e análises de fatias tomográficas de raios-X em alta resolução. Sua validação foi estabelecida a partir da estruturação de bancos de fatias tomográficas obtidas em alta resolução (resolução espacial de $8,54\mu\text{m}$), considerando as sementes agrícolas oleaginosas de girassol (*Helianthus annuus* L.), de pinhão-manso (*Jatropha curcas* L.) e de soja (*Glycine max* (L.) Merrill).

Para a avaliação das técnicas utilizadas para a configuração do método foi necessário avaliar cada processo envolvido na etapa de pré-processamento, assim como foi preciso na segmentação das imagens de sementes oleaginosas. Neste sentido, para a etapa do pré-processamento das fatias tomográficas, verificou-se utilizando as métricas PSNR, MSE e SSIM que os filtros *Non-local means* ($52,67\text{dB} \leq \text{PSNR} \leq 54,39\text{dB}$, $0,23 \leq \text{MSE} \leq 0,34$ e o melhor SSIM encontrado igual à 0,99) e Gaussiano ($23,74\text{dB} \leq \text{PSNR} \leq 24,70\text{dB}$, $252,90 \leq \text{MSE} \leq 272,89$ e o melhor SSIM encontrado igual à 0,88) apresentaram melhores resultados que os filtros de difusão anisotrópica e o passa-banda ideal, concluindo assim que eles são mais indicados para a composição do método.

Para a etapa de segmentação das imagens, as técnicas de limiarização simples e a técnica de grafos apresentaram os melhores resultados conforme foi observado conclusivamente pelos valores obtidos com a métrica DSC, as quais foram dadas por 0,91 e 0,90 respectivamente.

Uma inovação a ser observada no cumprimento dos objetivos específicos refere-se à

utilização integrada dos resultados de extração de características com o uso das técnicas de HOG e dos momentos invariantes de Hu, o que foi possível devido ao uso da técnica PCA.

Neste contexto, o vetor de características integrado com as informações de textura e as características geométricas pôde ser redimensionado, passando de um total de 8107 características para a dimensionalidade de 125 características. Tal iniciativa, levou a uma melhoria significativa no desempenho para a obtenção das características das fatias tomográficas que foram previamente segmentadas.

Quanto à avaliação dos classificadores supervisionados, que utilizaram o vetor de características estabelecido com a técnica PCA, foi possível concluir que a melhor escolha se contextualizou quando foi utilizado uma relação de 80% para 20% para treinamentos e testes respectivamente. Assim, foi observada a acurácia de 94% e 82% para os classificadores SVM e Naïve Bayes respectivamente. Entretanto, ao se observar a precisão desses classificadores em relação às fatias tomográficas para as diferentes sementes agrícolas, foi possível concluir que quanto à classificação de fatia tomográfica da semente de girassol, a melhor classificação foi realizada pelo classificador Naïve Bayes. Esse tipo de classificador apresentou uma precisão de 95% para as fatias tomográficas de sementes de girassol sem defeitos e 100% para as fatias tomográficas de sementes de girassol com defeitos. Por outro lado, quanto à classificação de fatia tomográfica da semente de pinhão-manso, o classificador SVM apresentou uma melhor precisão, ou seja, uma precisão de 100% tanto para fatias tomográficas de sementes de pinhão-manso sem defeitos quanto para as fatias tomográficas de sementes de pinhão-manso com defeitos. O mesmo ocorreu para a classificação de fatias tomográficas da semente de soja, ou seja, a melhor escolha indicou o classificador SVM que apresentou uma precisão de 81% para fatias tomográficas de sementes de soja sem defeitos e 91% para as fatias tomográficas de sementes de soja com defeitos.

6.2 Principal Contribuição

A principal contribuição desta pesquisa foi o desenvolvimento do método para a classificação de fatias tomográficas em alta resolução de sementes agrícolas oleaginosas, de boa qualidade e defeituosas, a partir da avaliação e integração de técnicas do processamento, de visualização de imagens e dos seus respectivos algoritmos. Esta iniciativa possibilita o estabelecimento de uma adaptabilidade de classificadores supervisionados para a aplicação em diferentes tipos de sementes agrícolas oleaginosas. Sua aplicabilidade visa o auxílio à tomada de decisão na seleção dessas sementes para o plantio. Tal abordagem se caracterizou como uma contribuição para os ganhos de competitividade no processo produtivo agroalimentar e energético, assim como, principalmente, contribuiu para a evolução de métodos obtidos a partir das técnicas do processamento e visualização de imagens digitais.

6.3 Proposta para Trabalhos Futuros

Como contribuição para trabalhos futuros foram considerados:

- Estudar e avaliar a viabilidade de incluir avaliação de técnicas de segmentação baseados em *Wathershed* e usos de Algoritmos Genéticos;
- Evoluir o método desenvolvido considerando o uso de classificadores não supervisionados para a etapa classificação das fatias tomográficas de sementes agrícolas oleaginosas;

REFERÊNCIAS

AHMED, I.; AHMAD, Z.; ISLAM, M.; ADNAN, A. A real-time specific weed recognition system by measuring weeds density through mask operation. In: *Innovations and Advanced Techniques in Systems, Computing Sciences and Software Engineering*. [S.l.: s.n.], 2008. ISBN 9781402087349. Citado na página 35.

ALMEIDA, F.; JERÔNIMO, E.; ALVES, N.; GOMES, J.; SILVA, A. Estudo de técnicas para o armazenamento de cinco oleaginosas em condições ambientais e criogênicas. *Revista Brasileira de Produtos Agroindustriais*, v. 12, n. 2, p. 189–202, 2010. ISSN 1517-8595. Citado na página 73.

ALVAREZ, L.; LIONS, P. L.; MOREL, J. M. Image selective smoothing and edge detection by nonlinear diffusion. II. *SIAM Journal on Numerical Analysis*, 1992. ISSN 00361429. Citado na página 28.

ALVES, G. M. *Método fundamentado em processamento digital de imagens para contagem automática de unidades formadoras de colônias*. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2006. Citado na página 64.

AMER, A.; DUBOIS, E. Fast and reliable structure-oriented video noise estimation. *IEEE Transactions on Circuits and Systems for Video Technology*, 2005. ISSN 10518215. Citado na página 46.

ARAÚJO, S. A.; PIRES, A. C.; SANTANA, J. C. C. Classificação automática de sementes de feijão usando técnicas de visão computacional. p. 1–11, 2011. Citado na página 21.

ARGENTI, F.; LAPINI, A.; ALPARONE, L.; BIANCHI, T. A tutorial on speckle reduction in synthetic aperture radar images. *IEEE Geoscience and Remote Sensing Magazine*, 2013. ISSN 21686831. Citado na página 50.

ARRUDA, F. P. de; BELTRÃO, N. E. d. M.; ANDRADE, A. P. de; PEREIRA, W. E.; SEVERINO, L. S. Cultivo de pinhão manso (*Jatropha curca* L.) como alternativa para o semi-árido nordestino. *Rev. bras. ol. fibras*, v. 8, n. 1, 2004. ISSN 1980-4830. Citado na página 72.

ATTIVISSIMO, F.; CAVONE, G.; LANZOLLA, A. M. L.; SPADAVECCHIA, M. A technique to improve the image quality in computer tomography. *IEEE Transactions on Instrumentation and Measurement*, 2010. ISSN 00189456. Citado na página 29.

BANHAM, M. R.; KATSAGGELOS, A. K. Digital image restoration. *IEEE Signal Processing Magazine*, 1997. ISSN 10535888. Citado 2 vezes nas páginas 9 e 47.

BARLETT, P. F. *Agricultural decision making: Anthropological contributions to rural development*. [S.l.]: Academic Press, 2016. Citado na página 21.

BEGAZO, D. C.; RODRÍGUEZ, D. Z.; RAMÍREZ, M. A. Avaliação de qualidade de vídeo sobre uma rede ip usando métricas objetivas. In: *Conferência Iberoamericana em Sistema, Cibernética e Informática CISCI*. [S.l.: s.n.], 2011. p. 226–229. Citado na página 59.

BELTRÃO, N. d. M.; OLIVEIRA, M. de. Oleaginosas e seus óleos: vantagens e desvantagens para produção de biodiesel. *Embrapa Algodão. Documentos*, n. 201, p. 28, 2008. ISSN 0103-0205. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/CNPA-2009-09/22146/1/DOC201.pdf>>. Citado na página 71.

BERALDO, J. M.; JUNIOR, F. d. A. S.; CRUVINEL, P. E. Application of x-ray computed tomography in the evaluation of soil porosity in soil management systems. *Engenharia Agrícola, Sociedade Brasileira de Engenharia Agrícola (SBEA)*, v. 34, n. 6, p. 1162–1174, 2014. ISSN 18084389. Citado 3 vezes nas páginas 9, 25 e 41.

BEUCHER, S.; MEYER, F. The morphological approach to segmentation: the watershed transformation. *Mathematical morphology in image processing*. In: *Optical Engineering*. [S.l.: s.n.], 1993. Citado na página 53.

BIASSUSI, M.; PAULETTO, E. A.; CRESTANA, S. Estudo da deformação de um Vertissolo por meio da tomografia computadorizada de dupla energia simultânea. *Revista Brasileira de Ciência do Solo*, 1999. ISSN 0100-0683. Citado na página 25.

BISHOP, C. M. *Machine Learning and Pattern Recognition*. [S.l.: s.n.], 2006. ISBN 9780387310732. Citado na página 64.

BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. Training algorithm for optimal margin classifiers. In: *Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory*. [S.l.: s.n.], 1992. ISBN 089791497X. Citado na página 65.

BOYKOV, Y. Y.; JOLLY, M. P. Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images. In: *Proceedings of the IEEE International Conference on Computer Vision*. [S.l.: s.n.], 2001. p. 105–112. Citado 3 vezes nas páginas 9, 57 e 58.

BRITO, A. R. de; CRUVINEL, P. E. Tomographic image segmentation model for features extraction of oilseeds based on graph theory. In: *2020 IEEE 14th International Conference on Semantic Computing (ICSC)*. [S.l.: s.n.], 2020. p. 341–346. ISSN 2325-6516. Citado na página 33.

BROX, T.; WEICKERT, J.; BURGETH, B.; MRÁZEK, P. Nonlinear structure tensors. *Image and Vision Computing*, 2006. ISSN 02628856. Citado na página 28.

BUADES, A.; COLL, B.; MOREL, J. M. A non-local algorithm for image denoising. In: *Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005*. [S.l.: s.n.], 2005. ISBN 0769523722. Citado 3 vezes nas páginas 28, 49 e 50.

BUADES, A.; COLL, B.; MOREL, J. M. Image denoising methods. A new nonlocal principle. *SIAM Review*, 2010. ISSN 00361445. Citado na página 50.

CANNY, J. A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986. ISSN 01628828. Citado na página 53.

Capelozza Filho, L.; FATTORI, L.; MALTAGLIATI, L. Á. Um novo método para avaliar as inclinações dentárias utilizando a tomografia computadorizada. *Revista Dental Press de Ortodontia e Ortopedia Facial*, 2005. ISSN 1415-5419. Citado na página 24.

CARDARELLI, E.; FISCHANGER, F. 2d data modelling by electrical resistivity tomography for complex subsurface geology. *Geophysical Prospecting*, v. 54, n. 2, p. 121–133, 2006. ISSN 00168025. Citado na página 24.

CASTRO, C. d.; CASTIGLIONI, V.; BALLA, A.; LEITE, R. D. C.; KARAM, D.; MELLO, C.; GUEDES, L.; FARIAS, J. A cultura do girassol. *Embrapa Soja-Circular Técnica (INFOTECA-E)*, Londrina, EMBRAPA-CNPQ. 1996. 38p.(EMBRAPA-CNPQ. Circular técnica. 13)., 1996. Citado na página 71.

CAVALCANTE, A. K.; SOUSA, L. B. de; HAMAWAKI, O. T. Determinação e avaliação do teor de óleo em sementes de soja pelos métodos de ressonância magnética nuclear e soxhlet. *Bioscience Journal*, v. 27, n. 1, 2011. ISSN 15163725. Citado na página 73.

CERQUEIRA, P. H. R. *Um estudo sobre reconhecimento de padrões: um aprendizado supervisionado com classificador bayesiano*. Tese (Doutorado) — Universidade de São Paulo, 2010. Citado na página 68.

CESTNIK, B. Estimating probabilities: a crucial task in machine learning. In: *Proceedings of the European Conference on Artificial Intelligence*. [S.l.: s.n.], 1990. p. 147–149. Citado na página 68.

CHAKI, J.; PAREKH, R. Designing an automated system for plant leaf recognition. *International Journal of Advances in Engineering & Technology*, v. 2, n. 1, p. 149, 2012. Citado na página 36.

CHAPELLE, O.; SCHOLKOPF, B.; ZIEN, A. Semi-supervised learning (chappelle, o. et al., eds.; 2006)[book reviews]. *IEEE Transactions on Neural Networks*, v. 20, n. 3, p. 542–542, 2009. Citado na página 69.

CHAUHAN, A. S.; SILAKARI, S.; DIXIT, M. Image segmentation methods: A survey approach. In: *Proceedings - 2014 4th International Conference on Communication Systems and Network Technologies, CSNT 2014*. [S.l.: s.n.], 2014. ISBN 9781479930708. Citado 2 vezes nas páginas 32 e 33.

CHENG, F.; YING, Y. B. Machine vision inspection of rice seed based on Hough transform. *Journal of Zhejiang University: Science*, 2004. ISSN 10093095. Citado na página 21.

CORMACK, A. M. Representation of a function by its line integrals, with some radiological applications. *Journal of Applied Physics*, 1963. ISSN 00218979. Citado na página 24.

CORTES, C.; VAPNIK, V. Support-Vector Networks. *Machine Learning*, 1995. ISSN 15730565. Citado 2 vezes nas páginas 65 e 66.

COSER, L. *Filtro de difusão anisotrópico orientado por evidência de borda*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 2009. Citado na página 28.

COSTA, C. J.; MARCHI, E. C. S. Germinação de sementes de palmeiras com potencial para produção de agroenergia. *Informativo Abrates*, 2008. Citado na página 71.

COSTA, L. d. F. D.; CESAR JR., R. M. *Shape Analysis and Classification: Theory and Practice*. 1st. ed. Boca Raton, FL, USA: CRC Press, Inc., 2000. ISBN 0849334934. Citado 3 vezes nas páginas 54, 65 e 68.

CRESTANA, S.; CRUVINEL, P.; VAZ, C.; CESAREO, R.; MASCARENHAS, S.; REICHARDT, K. Calibração e uso de um tomógrafo computadorizado em ciência do solo. *Revista brasileira de ciência do solo*, Sociedade Brasileira de Ciência do Solo, v. 16, n. 2, p. 161–167, 1992. Citado na página 25.

CRESTANA, S.; MASCARENHAS, S.; POZZI-MUCELLI, R. S. Static and dynamic three-dimensional studies of water in soil using computed tomographic scanning. *Soil Science*, 1985. ISSN 15389243. Citado na página 25.

CRISTIANINI, N.; SHAW-TAYLOR, J. *An introduction to support vector machines and other kernel-based learning methods*. [S.l.]: Cambridge university press, 2000. Citado 2 vezes nas páginas 10 e 66.

CRUVINEL, P. E. *Minitomógrafo de raio-X e raio gama computadorizado para aplicações multidisciplinares*. Tese (Doutorado) — Universidade Estadual de Campinas, 1987. Citado na página 25.

CRUVINEL, P. E.; CESAREO, R.; CRESTANA, S.; MASCARENHAS, S. X-and γ -Rays Computerized Minitomograph Scanner for Soil Science. *IEEE Transactions on Instrumentation and Measurement*, 1990. ISSN 15579662. Citado na página 25.

CRUVINEL, P. E.; PEREIRA, M. F. L.; SAITO, J. H.; COSTA, L. d. F. Performance improvement of tomographic image reconstruction based on dsp processors. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 58, n. 9, p. 3295–3304, 2009. Citado na página 25.

CRUVINEL, P. E.; VIEIRA, S. R.; CRESTANA, S.; MINATEL, E. R.; MUCHERONI, M. L.; NETO, A. T. Image processing in automated measurements of raindrop size and distribution. *Computers and Electronics in Agriculture*, 1999. ISSN 01681699. Citado 2 vezes nas páginas 21 e 27.

DALAL, N. *Finding people in images and videos*. Tese (Doutorado) — Institut National Polytechnique de Grenoble-INPG, 2006. Citado 2 vezes nas páginas 9 e 61.

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: *Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005*. [S.l.: s.n.], 2005. ISBN 0769523722. Citado na página 60.

DAMASCENO, M.; LEITE, T. P. C.; FRERY, A. C.; ALMIRON, M. G.; MURACT, A. Análise multivariada de imagens hiperespectrais na plataforma {R}. In: *XIII Simposio Brasileiro de Sensoriamento Remoto*. [S.l.: s.n.], 2007. Citado na página 21.

DEMIRKAYA, O. <title>Reduction of noise and image artifacts in computed tomography by nonlinear filtration of projection images</title>. In: *Medical Imaging 2001: Image Processing*. [S.l.: s.n.], 2001. Citado na página 28.

DENG, G.; CAHILL, L. W. Adaptive Gaussian filter for noise reduction and edge detection. In: *IEEE Nuclear Science Symposium & Medical Imaging Conference*. [S.l.: s.n.], 1994. ISBN 0780314875. Citado na página 49.

DEVNANI, A.; RAWAT, C. Comparative analysis of image quality measures. In: *2016 International Conference on Global Trends in Signal Processing, Information Computing and Communication (ICGTSPICC)*. [S.l.: s.n.], 2016. p. 353–357. Citado 4 vezes nas páginas 30, 31, 58 e 59.

DIOGO, L. P.; BAHLIS, L. F.; CARVALHAL, G. F. Computerized Tomography Contrast Induced Nephropathy (CIN) among adult inpatients. *Brazilian Journal of Nephrology*, scielo, v. 36, p. 446 – 450, 12 2014. ISSN 0101-2800. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0101-28002014000400446&nrm=iso>. Citado na página 24.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. [S.l.]: Wiley-Interscience, 2000. Citado 3 vezes nas páginas 65, 67 e 68.

DUSSCHOTEN, D. van; METZNER, R.; KOCHS, J.; POSTMA, J. A.; PFLUGFELDER, D.; BÜHLER, J.; SCHURR, U.; JAHNKE, S. Quantitative 3D analysis of plant roots growing in soil using magnetic resonance imaging. *Plant Physiology*, 2016. ISSN 15322548. Citado na página 21.

EDMONDS, J.; KARP, R. M. Theoretical Improvements in Algorithmic Efficiency for Network Flow Problems. *Journal of the ACM (JACM)*, 1972. ISSN 1557735X. Citado 2 vezes nas páginas 33 e 79.

ESPINDOLA, G. M.; CAMARA, G.; REIS, I. A.; BINS, L. S.; MONTEIRO, A. M. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. *International Journal of Remote Sensing*, 2006. ISSN 13665901. Citado na página 32.

EUSTÁQUIO, J.; QUEIROZ, R. D.; GOMES, H. M. *Introdução ao Processamento Digital de Imagens*. [S.l.: s.n.], 2001. ISSN 85-240-0762-1. ISBN 8524007621. Citado na página 48.

FEOFILOFF, P.; KOHAYAKAWA, Y.; WAKABAYASHI, Y. Uma Introdução Sucinta à Teoria dos Grafos. 2009. Citado na página 57.

FERNÁNDEZ, C. C. C. *Novos algoritmos de aprendizado para classificação de padrões utilizando floresta de caminhos ótimos*. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2011. Citado na página 68.

FIGUEIREDO, M. A.; JAIN, A. K. Unsupervised learning of finite mixture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002. ISSN 01628828. Citado na página 68.

FILHO, O. M.; NETO, H. V. *Processamento digital de imagens*. [S.l.]: Brasport, 1999. Citado 5 vezes nas páginas 9, 46, 48, 52 e 54.

FORD, L.; FULKERSON, D. *Flows in networks*. Princeton University Press., 1962. Citado na página 33.

FRANÇA, A. M. da S.; FLORENZANO, T. G.; NOVO, E. M. L. de M. Avaliação de fusão de imagens ópticas e microondas no mapeamento de morfologias lacustres. *Revista Brasileira de Cartografia*, v. 59, n. 2, 2007. Disponível em: <<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/view/44904>>. Citado na página 21.

FRANÇA-NETO, J. d. B.; PEREIRA, L. G.; COSTA, N. P. da; KRZYZANOWSKI, F.; HENNING, A. Metodologia do teste de tetrazólio em semente de soja. *Embrapa Soja-Documentos (INFOTECA-E)*, Londrina: EMBRAPA-CNPSo., 1988. Citado na página 73.

FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian Network Classifiers. *Machine Learning*, v. 29, n. 2-3, p. 131–163, 1997. ISSN 08856125. Citado 2 vezes nas páginas 67 e 68.

GEARY, D. N.; MCLACHLAN, G. J.; BASFORD, K. E. Mixture Models: Inference and Applications to Clustering. *Journal of the Royal Statistical Society. Series A (Statistics in Society)*, 1989. ISSN 09641998. Citado na página 68.

GIRALDO, J. C.; KELM, Z. S.; GUIMARAES, L. S.; YU, L.; FLETCHER, J. G.; ERICKSON, B. J.; MCCOLLOUGH, C. H. Comparative study of two image space noise reduction methods for computed tomography: Bilateral filter and nonlocal means. In: *Proceedings of the 31st Annual International Conference of the IEEE Engineering in Medicine and Biology Society: Engineering the Future of Biomedicine, EMBC 2009*. [S.l.: s.n.], 2009. ISBN 9781424432967. Citado na página 29.

GOLDFARB, M.; DUARTE, M. E. M.; MATA, M. E. R. C. Armazenamento criogênico de sementes de pinhão manso (*Jatropha curcas* L.) *euphorbiaceae*. *Biotemas*, v. 23, n. 1, p. 27–33, 2010. ISSN 2175-7925. Disponível em: <<https://periodicos.ufsc.br/index.php/biotemas/article/view/2175-7925.2010v23n1p27>>. Citado na página 72.

GONZALEZ, R. C.; WOODS, R. E. Digital image processing addison-wesley. *Reading, Ma*, v. 2, 1992. Citado 2 vezes nas páginas 9 e 48.

GONZALEZ, R. C.; WOODS, R. E. Digital Image Processing (3rd Edition). 2007. Citado 7 vezes nas páginas 9, 44, 49, 52, 53, 54 e 64.

GRADY, L. Random walks for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 28, n. 11, p. 1768–1783, 2006. ISSN 1939-3539. Citado na página 53.

GRANITTO, P. M.; VERDES, P. F.; CECCATTO, H. A. Large-scale investigation of weed seed identification by machine vision. *Computers and Electronics in Agriculture*, 2005. ISSN 01681699. Citado na página 37.

GREIG, D. M.; PORTEOUS, B. T.; SEHEULT, A. H. Exact maximum a posteriori estimation for binary images. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 51, n. 2, p. 271–279, 1989. Citado na página 57.

GROSS, J. L.; YELLEN, J. *Graph theory and its applications*. [S.l.]: Chapman and Hall/CRC, 2005. Citado 2 vezes nas páginas 10 e 80.

GUBERN-MÉRIDA, A.; KALLENBERG, M.; MARTÍ, R.; KARSSEMEIJER, N. Segmentation of the pectoral muscle in breast MRI using atlas-based approaches. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. [S.l.: s.n.], 2012. ISBN 9783642334177. ISSN 16113349. Citado na página 30.

GUERRERO, J. M.; PAJARES, G.; MONTALVO, M.; ROMEO, J.; GUIJARRO, M. Support vector machines for crop/weeds identification in maize fields. *Expert Systems with Applications*, v. 39, n. 12, p. 11149–11155, 2012. Citado na página 38.

GUYON, I.; BOSER, B.; VAPNIK, V. Automatic capacity tuning of very large vc-dimension classifiers. In: *Proceedings of the 5th International Conference on Neural Information Processing Systems*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1992. (NIPS'92), p. 147–155. ISBN 1558602747. Citado na página 66.

HAINSWORTH, J.; AYLMOORE, L. The use of computer assisted tomography to determine spatial distribution of soil water content. *Soil Research*, v. 21, n. 4, p. 435–443, 1983. ISSN 00049573. Citado na página 25.

- HANG, K. Real-time image acquisition and processing system design based on dsp. In: *2010 The 2nd International Conference on Computer and Automation Engineering (ICCAE)*. [S.l.: s.n.], 2010. v. 4, p. 492–496. Citado na página 26.
- HARTIGAN, J. A.; WONG, M. A. Algorithm AS 136: A K-Means Clustering Algorithm. *Applied Statistics*, 1979. ISSN 00359254. Citado 2 vezes nas páginas 32 e 68.
- HELENA, R.; FANTINATTI, J.; GROTH, D.; USBERTI, R. Qualidade física, fisiológica e sanitária de sementes de girassol de diferentes tamanhos. *Revista Brasileira de Sementes*, v. 23, n. 1, p. 134–139, 2001. ISSN 0101-3122. Citado 2 vezes nas páginas 71 e 72.
- HOLDER, D. *Electrical Impedance Tomography: Methods, History and Applications*. [S.l.]: CRC Press, 2004. Citado na página 24.
- HOTELLING, H. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 1933. ISSN 00220663. Citado na página 69.
- HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part 1. description of system. *The British journal of radiology*, v. 46, n. 552, p. 1016–1022, 1973. Citado 3 vezes nas páginas 9, 24 e 40.
- HSIAO, P. Y.; CHOU, S. S.; HUANG, F. C. Generic 2-D gaussian smoothing filter for noisy image processing. *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, v. 2, n. 2, 2007. Citado na página 49.
- HU, M. K. Visual Pattern Recognition by Moment Invariants. *IRE Transactions on Information Theory*, 1962. ISSN 21682712. Citado 3 vezes nas páginas 34, 61 e 62.
- HUANG, Z.; LENG, J. Analysis of Hu's moment invariants on image scaling and rotation. In: *ICCET 2010 - 2010 International Conference on Computer Engineering and Technology, Proceedings*. [S.l.: s.n.], 2010. ISBN 9781424463503. Citado na página 36.
- JAIN, A. K. *Fundamentals of digital image processing*. [S.l.]: Englewood Cliffs, NJ: Prentice Hall, 1989. Citado na página 53.
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 1, p. 4–37, 2000. ISSN 1939-3539. Citado 3 vezes nas páginas 9, 63 e 64.
- JIANG, L.; ZHANG, H.; CAI, Z.; SU, J. One dependence augmented naive bayes. In: *Advanced Data Mining and Applications*. [S.l.]: Springer Berlin Heidelberg, 2005. p. 186–194. ISBN 978-3-540-31877-4. Citado na página 68.
- JÚNIOR, E. A.; YAMASHITA, H. Aspectos básicos de tomografia computadorizada e ressonância magnética. *Revista Brasileira de Psiquiatria*, v. 23, p. 2–3, 2001. ISSN 1516-4446. Citado na página 21.
- JÚNIOR, O. A. C.; CARVALHO, A. P.; MENESES, P. R.; GUIMARÃES, R. F. Classificação e eliminação dos ruídos em imagens hiperespectrais pela análise sequencial da transformação por fração de ruído mínima. *Revista Brasileira de Geofísica*, v. 20, p. 31 – 41, 2002. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-261X2002000100003&nrm=iso>. Citado na página 21.

KONONENKO, I. Semi-naive bayesian classifier. In: *Machine Learning — EWSL-91*. [S.l.]: Springer Berlin Heidelberg, 1991. p. 206–219. ISBN 978-3-540-46308-5. Citado na página 68.

KURUVILLA, J.; SUKUMARAN, D.; SANKAR, A.; JOY, S. P. A review on image processing and image segmentation. In: *2016 International Conference on Data Mining and Advanced Computing (SAPIENCE)*. [S.l.: s.n.], 2016. p. 198–203. Citado na página 32.

LAIA, M. A.; CRUVINEL, P. E.; GUNGOR, B. E. O. An application approach to kalman filter and ct scanners for soil science. In: *Principles, Application and Assessment in Soil Science*. [S.l.]: InTech, 2011. Citado na página 76.

LAIA, M. A.; LEVADA, A. L.; BOTEGA, L. C.; PEREIRA, M. F.; CRUVINEL, P. E.; MACEDO, Á. A novel model for combining projection and image filtering using Kalman and discrete wavelet transform in computerized tomography. In: *Proceedings - 2008 IEEE 11th International Conference on Computational Science and Engineering, CSE 2008*. [S.l.: s.n.], 2008. ISBN 9780769531939. Citado na página 25.

LAMMICH, P.; SEFIDGAR, S. R. Formalizing the edmonds-karp algorithm. In: *Interactive Theorem Proving*. [S.l.]: Springer International Publishing, 2016. p. 219–234. ISBN 978-3-319-43144-4. Citado na página 79.

LANGLEY, P.; IBA, W.; THOMPSON, K. Analysis of Bayesian classifiers. In: *Proceedings Tenth National Conference on Artificial Intelligence*. [S.l.: s.n.], 1992. ISBN 0262510634. Citado na página 67.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine learning in agriculture: A review. *Sensors (Switzerland)*, v. 18, n. 8, p. 1–29, 2018. ISSN 14248220. Citado na página 38.

LINDENBAUM, M.; FISCHER, M.; BRUCKSTEIN, A. On Gabor’s contribution to image enhancement. *Pattern Recognition*, 1994. ISSN 00313203. Citado na página 28.

LITOS, G.; ZABULIS, X.; TRIANTAFYLLIDIS, G. Synchronous image acquisition based on network synchronization. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2006. ISBN 0769526462. ISSN 10636919. Citado na página 25.

LIU, Y.-l.; LIANG, Y.; CHENG, Y.-y. Design and implementation of image acquisition system based on arm and linux. In: *IEEE. Proceedings of 2011 International Conference on Electronics and Optoelectronics*. [S.l.], 2011. v. 3, p. V3–49. Citado na página 26.

LLOYD, E. K.; BONDY, J. A.; MURTY, U. S. R. Graph Theory with Applications. *The Mathematical Gazette*, 1978. ISSN 00255572. Citado na página 57.

LLOYD, S. P. Least Squares Quantization in PCM. *IEEE Transactions on Information Theory*, 1982. ISSN 15579654. Citado na página 53.

LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007. Citado 2 vezes nas páginas 65 e 66.

LORIGADOS, C. A. B. *Utilização da ultra-sonografia modo B e da tomografia computadorizada no estudo do encéfalo de cães adultos*. Tese (Doutorado) — Universidade de São Paulo, 2008. Citado na página 24.

LU, W. L.; LITTLE, J. J. Simultaneous tracking and action recognition using the PCA-HOG descriptor. In: *Third Canadian Conference on Computer and Robot Vision, CRV 2006*. [S.l.: s.n.], 2006. ISBN 0769525423. Citado na página 34.

LUKAS, R. V. Two automobile collisions in one day. *Journal of Emergency Medicine*, v. 43, n. 4, p. e263–e264, 2012. Citado na página 24.

MATEI, R. Design of 2D parametric filters for directional Gaussian smoothing. In: *2013 European Conference on Circuit Theory and Design, ECCTD 2013 - Proceedings*. [S.l.: s.n.], 2013. ISBN 9783000437854. Citado na página 49.

MEKKITTIKUL, A.; MCKEOWN, N. Practical scheduling algorithm to achieve 100% throughput in input-queued switches. In: *Proceedings - IEEE INFOCOM*. [S.l.: s.n.], 1998. ISSN 0743166X. Citado na página 79.

MENESES, P. R.; ALMEIDA, T. d. et al. Introdução ao processamento de imagens de sensoria-mento remoto. *Universidade de Brasília, Brasília*, 2012. Citado na página 48.

MIDGLEY, P. A.; DUNIN-BORKOWSKI, R. E. *Electron tomography and holography in materials science*. 2009. Citado na página 24.

MINERVINI, M.; SCHARR, H.; TSAFTARIS, S. A. Image analysis: The new bottleneck in plant phenotyping [applications corner]. *IEEE Signal Processing Magazine*, 2015. ISSN 10535888. Citado na página 21.

MING, L. Image segmentation algorithm research and improvement. In: *2010 3rd International Conference on Advanced Computer Theory and Engineering(ICACTE)*. [S.l.: s.n.], 2010. v. 5, p. V5–211–V5–214. Citado na página 32.

MIRANDA, J.; NETO, J. Detecção de bordas com o modelo de difusão anisotrópica. *XIII Simpósio Brasileiro de Sensoriamento Remoto*, p. 5957–5964, 2007. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2006/09.22.21.00/doc/5957-5964.pdf>>. Citado na página 28.

MIYAMOTO, B. S. *Método de processamento digital de imagens para inferência da qualidade de materiais preparados com fibras vegetais*. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2013. Citado na página 36.

MONDO, V. H. V.; CICERO, S. M. Análise de imagens na avaliação da qualidade de sementes de milho localizadas em diferentes posições na espiga. *Revista Brasileira de Sementes*, 2005. ISSN 0101-3122. Citado na página 21.

MOROZKIN, P.; SWYNGHEDAUW, M.; TROCAN, M. Design of an embedded image acquisition system. In: *2015 IEEE International Conference on Electronics, Circuits, and Systems (ICECS)*. [S.l.: s.n.], 2015. p. 504–505. Citado na página 26.

NAIME, J. d. M. *Projeto e construção de um tomógrafo portátil para estudos de ciência do solo e plantas, em campo*. Dissertação (Mestrado) — Universidade de São Paulo, 1994. Citado na página 25.

NETO, J. F. B. *Agricultura de decisão para clarear o futuro*. 2017. Disponível em: <<http://www.agrobiz.com.br/assets/uploads/news/news-9.pdf>>. Acesso em: 11-08-2019. Citado na página 21.

- ONYANGO, C. M.; MARCHANT, J. A. Segmentation of row crop plants from weeds using colour and morphology. *Computers and Electronics in Agriculture*, 2003. ISSN 01681699. Citado na página 31.
- OPPENHEIM, A. V.; WILLSKY, A. S.; NAWAB, S. H. *Señales y sistemas*. [S.l.]: Pearson Educación, 1998. Citado 2 vezes nas páginas 9 e 53.
- OTSU, N. THRESHOLD SELECTION METHOD FROM GRAY-LEVEL HISTOGRAMS. *IEEE Trans Syst Man Cybern*, 1979. ISSN 00189472. Citado 4 vezes nas páginas 32, 53, 54 e 56.
- PAL, N. R.; PAL, S. K. A review on image segmentation techniques. *Pattern Recognition*, 1993. ISSN 00313203. Citado 2 vezes nas páginas 53 e 54.
- PASSONI, S. *Microtomografia de raios-X na caracterização micromorfológica de solo submetido a diferentes manejos*. Dissertação (Mestrado) — Universidade Estadual de Ponta Grossa, 2013. Citado na página 21.
- PAULUS, M. J.; GLEASON, S. S.; KENNEL, S. J.; HUNSICKER, P. R.; JOHNSON, D. K. *High resolution X-ray computed tomography: An emerging tool for small animal cancer research*. 2000. Citado na página 24.
- PEARSON, K. LIII. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 1901. ISSN 1941-5982. Citado na página 69.
- PEREIRA, M. F. L. *Um modelo de reconstrução tomográfica 3D para amostras agrícolas com filtragem de Wiener em processamento paralelo*. Tese (Doutorado) — Universidade de São Paulo, 2007. Citado na página 78.
- PEREIRA, M. F. L.; CRUVINEL, P. E. A model for soil computed tomography based on volumetric reconstruction, wiener filtering and parallel processing. *Computers and Electronics in Agriculture*, Elsevier, v. 111, p. 151–163, 2015. Citado 3 vezes nas páginas 9, 25 e 41.
- PERONA, P.; MALIK, J. Scale-Space and Edge Detection Using Anisotropic Diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990. ISSN 01628828. Citado 3 vezes nas páginas 28, 50 e 52.
- PERONA, P.; SHIOTA, T.; MALIK, J. Anisotropic diffusion. In: *Geometry-driven diffusion in computer vision*. [S.l.]: Springer, 1994. p. 73–92. Citado 2 vezes nas páginas 9 e 51.
- PETROVIC, A. M.; SIEBERT, J. E.; RIEKE, P. E. Soil bulk density analysis in three dimensions by computed tomographic scanning. *Soil Science Society of America Journal*, 1982. ISSN 03615995. Citado na página 25.
- PFLUGFELDER, D.; METZNER, R.; DUSSCHOTEN, D. van; REICHEL, R.; JAHNKE, S.; KOLLER, R. Non-invasive imaging of plant roots in different soils using magnetic resonance imaging (mri). *Plant methods*, BioMed Central, v. 13, n. 1, p. 102, 2017. Citado na página 21.
- PICOZZI, M.; PAROLAI, S.; BINDI, D.; STROLLO, A. Characterization of shallow geology by high-frequency seismic noise tomography. *Geophysical Journal International*, 2009. ISSN 0956540X. Citado na página 24.

PINHEIRO, A. M. *Filtragem de sinograma tomográfico afetado por ruído Poisson utilizando wavelets anisotrópicas*. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2017. Citado na página 76.

PITAS, I. *Digital image processing algorithms and applications*. 2000. Citado na página 54.

RADON, J. On determination of functions by their integral values along certain multiplicities. *Ber Verbhandl Sächs Akad Wiss Leipzig, Math-Phys Kl*, 1917. Citado na página 24.

RANGAYYAN, R. M. *Biomedical image analysis*. [S.l.: s.n.], 2004. ISSN 0017-9078. ISBN 9780203492543. Citado 5 vezes nas páginas 9, 41, 42, 43 e 44.

REIS, F. I. M. R. dos. *Detecção de pedestres em imagens: Uma nova abordagem baseada em redução de dimensionalidade e regras de detecção de outliers*. Dissertação (Mestrado) — Universidade de Lisboa., 2011. Citado 2 vezes nas páginas 25 e 60.

RIBEIRO, E. d. S. *Novas propostas em filtragem de projeções tomográficas sob ruído Poisson*. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2010. Citado na página 76.

ROMANI, E. *Avaliação de qualidade de vídeo utilizando modelo de atenção visual baseado em saliência*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2015. Citado na página 59.

ROSOT, N. C. *Integração de imagens de sensores de microondas e ópticos para fins de mapeamento e classificação de reflorestamentos no sul do Brasil*. Tese (Doutorado) — Universidade Federal de Santa Catarina., 2001. Citado na página 21.

RUDIN, L. I.; OSHER, S.; FATEMI, E. Nonlinear total variation based noise removal algorithms. *Physica D: Nonlinear Phenomena*, 1992. ISSN 01672789. Citado na página 28.

SAHAMI, M. Learning limited dependence bayesian classifiers. In: *Proceedings of 2nd International Conference in Knowledge Discovery and Data Mining*. [S.l.: s.n.], 1996. Citado na página 68.

SALINA, F. V. *Métodos híbridos para reconstrução tomográfica de imagens usando POCS e teoria da estimação*. Tese (Doutorado) — Universidade de São Paulo, 2007. Citado na página 44.

SALVADEO, D. H. P. *Filtragem de ruído em imagens tomográficas com baixa taxa de contagem utilizando uma abordagem Bayesiana contextual*. Tese (Doutorado) — Universidade Federal de São Carlos, 2013. Citado na página 42.

SALVO, L.; CLOETENS, P.; MAIRE, E.; ZABLER, S.; BLANDIN, J. J.; BUFFIÈRE, J. Y.; LUDWIG, W.; BOLLER, E.; BELLET, D.; JOSSEROND, C. X-ray micro-tomography an attractive characterisation technique in materials science. In: *Nuclear Instruments and Methods in Physics Research, Section B: Beam Interactions with Materials and Atoms*. [S.l.: s.n.], 2003. ISSN 0168583X. Citado na página 24.

SANTIAGO, V. S. *Aplicação de um Modelo de Difusão Anisotrópica e Morfologia Matemática na Detecção de Feições Cartográficas*. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), 2013. Citado na página 29.

SANTOS, A. d. O.; CRUVINEL, P. Desenvolvimento de um modelo de descritores de imagens para reconhecimento de padrões de plantas invasoras (folhas largas e folhas estreitas). In: XI ENCONTRO DE MODELAGEM COMPUTACIONAL. *Embrapa Instrumentação-Artigo em anais de congresso (ALICE)*. [S.l.], 2008. Citado na página 35.

SANTOS, A. P. d. O. *Desenvolvimento de descritores de imagens para reconhecimento de padrões de plantas invasoras (folhas largas e folhas estreitas)*. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2009. Citado 2 vezes nas páginas 20 e 64.

SANTOS, E. B. d. *A ordenação das variáveis no processo de otimização de classificadores bayesianos: Uma abordagem evolutiva*. Dissertação (Mestrado) — Universidade Federal de São Carlos, 2007. Citado na página 68.

SATURNINO, H.; PACHECO, D.; KAKIDA, J.; TOMINAGA, N.; GONÇALVES, N. Produção de oleaginosas para o biodiesel. *Informe Agropecuário*, v. 26, n. 229, p. 44–74, 2005. Citado na página 72.

SCHÜTZE, H.; MANNING, C. D.; RAGHAVAN, P. *An introduction to information retrieval*. [S.l.]: Cambridge University Press,, 2007. Citado 2 vezes nas páginas 10 e 65.

SEERAM, E. Computed tomography: Physical principles and recent technical advances. *Journal of Medical Imaging and Radiation Sciences*, 2010. ISSN 19398654. Citado 2 vezes nas páginas 9 e 42.

SHI, J.; MALIK, J. Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000. ISSN 01628828. Citado na página 57.

SILVA, H.; ALENCAR, M.; QUEIROZ, W.; COELHO, R. Mitigação do Ruído Impulsivo em Sistemas de Comunicações Digitais. In: . [S.l.: s.n.], 2017. Citado na página 46.

SKLANSKY, J. Image segmentation and feature extraction. *IEEE Transactions on Systems, Man and Cybernetics*, 1978. ISSN 00189472. Citado na página 31.

SMITH, S. M.; BRADY, J. M. SUSAN - A new approach to low level image processing. *International Journal of Computer Vision*, 1997. ISSN 09205691. Citado na página 28.

SOOD, S.; MAHAJAN, S.; DOEGAR, A.; DAS, A. Internal crack detection in kidney bean seeds using X-ray imaging technique. In: *2016 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2016*. [S.l.: s.n.], 2016. ISBN 9781509020287. Citado na página 33.

SOUZA, G. B.; ALVES, G. M.; LEVADA, A. L.; CRUVINEL, P. E.; MARANA, A. N. A graph-based approach for contextual image segmentation. *Proceedings - 2016 29th SIBGRAPI Conference on Graphics, Patterns and Images, SIBGRAPI 2016*, p. 281–288, 2016. Citado 3 vezes nas páginas 33, 52 e 53.

STUPPY, W. H.; MAISANO, J. A.; COLBERT, M. W.; RUDALL, P. J.; ROWE, T. B. Three-dimensional analysis of plant structure using high-resolution x-ray computed tomography. *Trends in plant science*, v. 8 1, p. 2–6, 2003. Citado na página 24.

SWETS, D. L. Using discriminant eigenfeatures for image retrieval. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1996. ISSN 01628828. Citado na página 100.

- TAKEDA, F. B.; CRUVINEL, P. E.; SAITO, J. H. Uma ferramenta para obtenção de imagens estereoscópicas em agropecuária e agroindústria. In: *CONGRESSO BRASILEIRO DA SOCIEDADE BRASILEIRA DE INFORMÁTICA APLICADA À AGROPECUÁRIA E AGROINDÚSTRIA-Sbi-Agro*. [S.l.: s.n.], 2003. v. 4. Citado na página 21.
- TELLAECHE, A.; BURGOS-ARTIZZU, X. P.; PAJARES, G.; RIBEIRO, A. A vision-based method for weeds identification through the Bayesian decision theory. *Pattern Recognition*, 2008. ISSN 00313203. Citado na página 38.
- THUNG, K. H.; RAVEENDRAN, P. A survey of image quality measures. In: *International Conference for Technical Postgraduates 2009, TECHPOS 2009*. [S.l.: s.n.], 2009. ISBN 9781424452231. Citado na página 30.
- TIAN, L.; SLAUGHTER, D.; NORRIS, R. Machine vision identification of tomato seedlings for automated weed control. *Transactions of ASAE*, v. 40, n. 6, p. 1761–1768, 2000. Citado na página 37.
- TOMASI, C.; MANDUCHI, R. Bilateral filtering for gray and color images. In: *Proceedings of the IEEE International Conference on Computer Vision*. [S.l.: s.n.], 1998. Citado na página 28.
- TOUCHELL, D. H.; DIXON, K. W. Cryopreservation for Seedbanking of Australian Species. *Annals of Botany*, 1994. ISSN 03057364. Citado na página 72.
- VARELLA, C. A. A. Análise de componentes principais. *Seropédica: Universidade Federal Rural do Rio de Janeiro*, 2008. Citado na página 69.
- VAZ, C. M.; De Maria, I. C.; LASSO, P. O.; TULLER, M. Evaluation of an advanced benchtop Micro-Computed Tomography system for quantifying porosities and pore-size distributions of two Brazilian Oxisols. *Soil Science Society of America Journal*, 2011. ISSN 03615995. Citado na página 25.
- WANG, Z.; BOVIK, A. C.; SHEIKH, H. R.; SIMONCELLI, E. P. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 2004. ISSN 10577149. Citado na página 59.
- WANG, Z.; ZHANG, D. Progressive switching median filter for the removal of impulse noise from highly corrupted images. *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, 1999. ISSN 10577130. Citado na página 47.
- WEBB, G. I.; BOUGHTON, J. R.; WANG, Z. Not so naive Bayes: Aggregating one-dependence estimators. *Machine Learning*, 2005. ISSN 08856125. Citado na página 68.
- WELLS, W. M. Efficient Synthesis of Gaussian Filters by Cascaded Uniform Filters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986. ISSN 01628828. Citado na página 49.
- WOLD, S.; ESBENSEN, K.; GELADI, P. Principal component analysis. *Chemometrics and Intelligent Laboratory Systems*, 1987. ISSN 01697439. Citado na página 69.
- XIU, L.; MA, B.; ZHU, K.; ZHANG, L. Implementation and optimization of image acquisition with smartphones in computer vision. In: *International Conference on Information Networking*. [S.l.: s.n.], 2018. ISBN 9781538622896. ISSN 19767684. Citado na página 27.

ZAMPOLO, R. de F.; GOMES, D. de A.; SEARA, R. Avaliação e comparação de métricas de referência completa na caracterização de limiões de detecção em imagens. *XXVI Simpósio Brasileiro de Telecomunicações-SBrT*, 2008. Citado na página 30.

ZHANG, H. The optimality of Naive Bayes. In: *Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference, FLAIRS 2004*. [S.l.: s.n.], 2004. ISBN 1577352017. Citado na página 68.

ZHU, S. C.; YUILLE, A. Region competition: unifying snakes, region growing, and bayes/mdl for multiband image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 18, n. 9, p. 884–900, Sep. 1996. ISSN 1939-3539. Citado na página 53.

ZOU, K. H.; WARFIELD, S. K.; BHARATHA, A.; TEMPANY, C. M.; KAUS, M. R.; HAKER, S. J.; WELLS, W. M.; JOLESZ, F. A.; KIKINIS, R. Statistical Validation of Image Segmentation Quality Based on a Spatial Overlap Index. *Academic Radiology*, 2004. ISSN 10766332. Citado 2 vezes nas páginas 58 e 59.

APÊNDICE A

ALGORITMOS

A.1 Pré-Processamento

Algorithm 1 Algoritmo para filtro Difusão Anisotrópica

Input: Imagem inicial, κ , Γ , numIter

Output: Imagem pré-processada

```

1 begin
2   Transformar imagem em escala de cinza
3   Seleciona a região de interesse
4   auxiliar <- 0
5   while (auxiliar <= numIter) do
6     imagem filtro <- filtro Difusão Anisotrópica(imagem,  $\kappa$ ,  $\Gamma$ )
7     auxiliar <- auxiliar + 1
8   end
9 end

```

Algorithm 2 Algoritmo para filtro no domínio da frequência

Input: Imagem inicial

Output: Imagem pré-processada

```

10 begin
11   Transformar imagem em escala de cinza
12   Selecionar região de interesse
13   Transformada da imagem para o domínio da frequência
14   Imagem filtrada <- filtro passa-banda(imagem na frequência,  $\sigma_1$ ,  $\sigma_2$ )
15   Transformada inversa da imagem no domínio da frequência
16 end

```

Algorithm 3 Algoritmo para filtro Gaussiano

Input: Imagem inicial, largura, altura, σ **Output:** Imagem pré-processada

```

17 begin
18   Transformar imagem em escala de cinza
19   Selecionar região de interesse
20   Imagem filtrada <- filtro gaussiano(imagem, (largura, altura),  $\sigma$ )
21 end

```

Algorithm 4 Algoritmo para filtro *non-local means*

Input: Imagem inicial, tamanho *patche*, distância *patche*, σ **Output:** Imagem pré-processada

```

22 begin
23   Transformar imagem em escala de cinza
24   Selecionar região de interesse
25   Imagem filtrada <- filtro non-local means(imagem, tamanho patche, distância patche,  $\sigma$ )
26 end

```

A.2 Segmentação

Algorithm 5 Algoritmo para segmentação Limiarização

Input: Imagem pré-processada, limiar**Output:** Imagem segmentada

```

27 begin
28   Imagem pré-processada
29   for cada pixel[i][j] da imagem de tamanho MxN do
30     if pixel[i][j]  $\geq$  limiar then
31       | pixel[i][j] <- 1
32     else
33       | pixel[i][j] <- 0
34     end
35   end
36 end

```

Algorithm 6 Algoritmo para segmentação Otsu

Input: Imagem pré-processada**Output:** Imagem segmentada

```

37 begin
38   Imagem pré-processada
39   Encontrar um limiar T usando a Equação 3.56
40   for cada pixel[i][j] da imagem de tamanho MxN do
41     if pixel[i][j] ≥ T then
42       | pixel[i][j] <- 1
43     else
44       | pixel[i][j] <- 0
45     end
46   end
47 end

```

Algorithm 7 Algoritmo para segmentação Grafo

Input: Imagem pré-processada**Output:** Imagem segmentada

```

48 begin
49   Imagem pré-processada
50   Equalizar do histograma da imagem
51   Definir os vértices virtuais referente a semente do objeto e semente fundo
52   Criar o grafo a partir da imagem
53   Atribuir os pesos para cada aresta presente no grafo
54   Conectar cada aresta ao grafo
55   Aplicar o algoritmo Edmonds-Karp para obtenção do fluxo máximo do grafo
56   Montagem da imagem
57 end

```

Algorithm 8 Algoritmo para obter as regiões referente ao objetos

Input: Imagem equalizada, ponto, comprimento, altura**Output:** Janela objeto

```

58 begin
59   Define o ponto central pertencente ao objeto na imagem
60   Seleciona todos os pixels vizinhos pertencendo ao objeto
61   Janela <- região selecionada pertencente ao objeto
62   soma <- 0
63   for cada pixel[i][j] da Janela de tamanho MxN do
64     | soma <- pixel[i][j] + soma
65   end
66   média <- soma / (comprimento x altura)
67 end

```

Algorithm 9 Algoritmo para obter as regiões referente ao fundo da imagem

Input: Imagem equalizada, ponto, comprimento, altura**Output:** Janela fundo

```

68 início
69   Definir o ponto central pertencente ao fundo na imagem
70   Selecionar todos os pixels vizinhos pertencendo ao fundo
71   Janela <- região pertencente ao fundo
72   soma <- 0
73   for cada pixel[i][j] da Janela de tamanho MxN do
74     | soma <- pixel[i][j] + soma
75   end
76   média <- soma / (comprimento x altura)
77 fim

```

Algorithm 10 Algoritmo aplicado para calcular o peso da aresta.

Input: Imagem equalizada, ponto1, ponto2**Output:** Peso da Aresta

```

78 begin
79   Imagem filtrada
80   lp,cp ← ponto1
81   lq,cq ← ponto2
82   peso ← 255 - |imagem[lp][cp] - imagem[lq][cq]|
83 end

```

Algorithm 11 Algoritmo aplicado para calcular o peso das arestas s e t.

Input: I_p, u_r, σ **Output:** Peso da Aresta

```

84 begin
85   | peso ←  $\frac{1}{\sqrt{2\pi\sigma}} \frac{-1}{2\sigma} (I_p - \mu)^2$ 
86 end

```

Algorithm 12 Algoritmo para obter a semente**Input:** Imagem equalizada, mediaS, mediaT**Output:** Imagem Grafo

```

87 begin
88   linha , coluna  $\leftarrow$  Imagem[0], Imagem[1]
89   G  $\leftarrow$  DiGrafo()
90   for cada i começando de 0 até linha do
91     for cada j começando de 0 até coluna do
92       if  $i > 0$  then
93         G.adicionaAresta(vertice[i][j], vértice[i-1][j], Capacidade  $\leftarrow$  Algoritmo 10 (Ima-
94           gem, (i,j), (i-1,j))
95       else if  $i < (linha - 1)$  then
96         G.adicionaAresta(vertice[i][j], vértice[i+1][j], Capacidade  $\leftarrow$  Algoritmo 10 (Ima-
97           gem, (i,j), (i+1,j))
98       else if  $j > 0$  then
99         G.adicionaAresta(vertice[i][j], vértice[i][j-1], Capacidade  $\leftarrow$  Algoritmo 10 (Ima-
100           gem, (i,j), (i,j-1))
101       else if  $i < (coluna - 1)$  then
102         G.adicionaAresta(vertice[i][j], vértice[i][j+1], Capacidade  $\leftarrow$  Algoritmo 10 (Ima-
103           gem, (i,j), (i,j+1))
104     end
105   for cada i começando de 0 até linha do
106     for cada j começando de 0 até coluna do
107       Grafo.adicionaAresta(s, vertice[i][j], Capacidade  $\leftarrow$  Algoritmo 11 (Imagem[i,j],
108         mediaS, varianciaS)))
109       Grafo.adicionaAresta(vertice[i][j], t, Capacidade  $\leftarrow$  Algoritmo 11 (Imagem[i,j],
110         mediaT, varianciaT)))
111     end
112   end
113 end

```

Algorithm 13 Montagem da imagem.

Input: Grupo, comprimento, altura**Output:** Imagem

```
109 begin
110   resultado[comprimento][altura]
111   for cada i começando de 0 até comprimento do
112     for cada i começando de 0 até altura do
113       resultado[i][j] ← 1
114     end
115   end
116   for cada v,u começando de 0 até Grupo.itens() do
117     auxiliar ← v.split('_')
118     linha ← auxiliar[0]
119     coluna ← auxiliar[1]
120     resultado[linha][coluna] ← 0
121   end
122 end
```

A.3 Extração de Características

Algorithm 14 Algoritmo para extração de características baseado em técnica HOG

Input: Imagem binarizada**Output:** Vetor de característica

```
123 begin
124   Aquisição da Imagem segmentada.
125   Realizar a conjunção entre a imagem binarizada e imagem pré-processada.
126   Normalização da imagem.
127   Definir o tamanho da janela para detecção do objeto.
128   Definir o tamanho do bloco para percorre sobre a janela.
129   Definir a quantidade de orientações para extrair as características.
130   Percorrer sobre cada bloco contido na janela e extrair suas características.
131 end
```

Algorithm 15 Algoritmo para extração de características baseado em momentos invariantes de Hu

Input: Imagem binarizada, tamanhoImagem

Output: Vetor de característica com 7 posições

```

132 Aquisição da Imagem segmentada.
133 Realizar a conjunção entre a imagem binarizada e imagem pré-processada.
134 Normalização da imagem.
135 Obter os momentos bidimensionais(tamanhoImagem,imagem)
136 Obter os momentos centrais(tamanhoImagem,imagem)
137 Obter os momentos centrais normalizado(tamanhoImagem,imagem)
138 begin
139   Obter o primeiro momento invariante de Hu (tamanhoImagem,imagem)
140   Obter o segundo momento invariante de Hu (tamanhoImagem,imagem)
141   Obter o terceiro momento invariante de Hu (tamanhoImagem,imagem)
142   Obter o quarto momento invariante de Hu (tamanhoImagem,imagem)
143   Obter o quinto momento invariante de Hu (tamanhoImagem,imagem)
144   Obter o sexto momento invariante de Hu (tamanhoImagem,imagem)
145   Obter o sétimo momento invariante de Hu (tamanhoImagem,imagem)
146 end

```

A.4 Análise de Componentes Principais

Algorithm 16 Algoritmo para redução de dimensionalidade

Input: Imagem, número de componentes

Output: Vetor de característica

```

147 Vetor de característica ← []
148 for Imagem até Imagem.itens() do
149   Vetor de característica HOG ← HOG(Imagem)
150   Vetor de característica Hu ← HOG(Imagem,tamanhoImagem)
151   Vetor de característica ← concatena[Vetor de característica HOG,Vetor de característica Hu]
152 end
153 Vetor de característica ← pca(Vetor de característica, número de componentes)

```

A.5 Classificação

Algorithm 17 Algoritmo para classificação do método SVM

Input: Id, Vetor de característica, tamanho

Output: Vetor de característica

```

154 Criar o classificador
155 vetor_características_treinamento, vetor_características_teste, id_treinamento, id_teste ← di-
    vide(Vetor de característica, Id, tamanho)
156 Treinar o classificador SVM(vetor_características_treinamento, id_treinamento)
157 Testar o classificador SVM(vetor_características_teste)

```

Algorithm 18 Algoritmo para treinamento do classificador Naïve Bayes

Input: Id, Vetor de característica, tamanho**Output:** Vetor de característica

```
158 Criar o classificador
159 vetor_características_treinamento, vetor_características_teste, id_treinamento, id_teste ← di-
    vide(Vetor de característica, Id, tamanho)
160 Treinar o classificador Naïve Bayes(vetor_características_treinamento, id_treinamento)
161 Testar o classificador Naïve Bayes(vetor_características_teste)
```

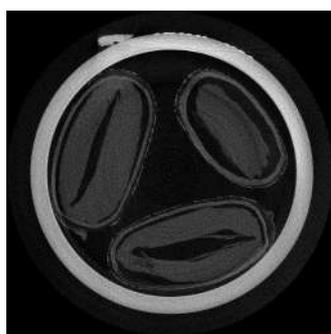
APÊNDICE B

RESULTADOS DAS ANÁLISES DAS MODALIDADES DE FILTRAGEM E SEGMENTAÇÃO DAS FATIAS TOMOGRÁFICAS

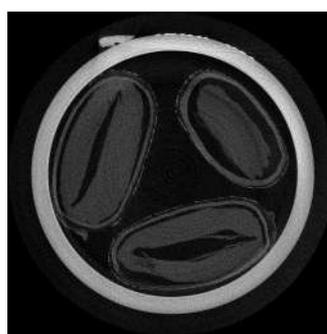
B.1 Pré-Processamento

B.1.1 Resultado do Filtro de Difusão Anisotrópica

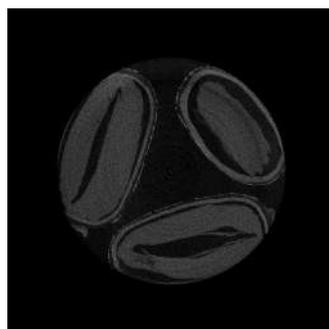
Figura 50 – Exemplo do resultado da aplicação do filtro de difusão anisotrópica aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-manso (50a), à fatia tomográfica após adição de ruído Gaussiano (50b), ao ROI fatia da tomográfica ruidosa (50c) e à fatia tomográfica após a aplicação do filtro (50d).



(a)



(b)

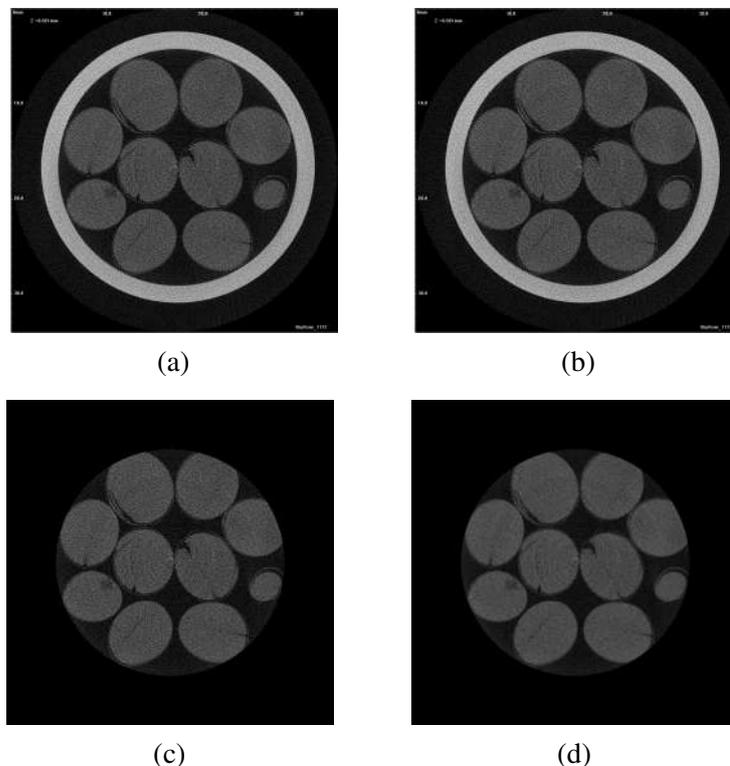


(c)



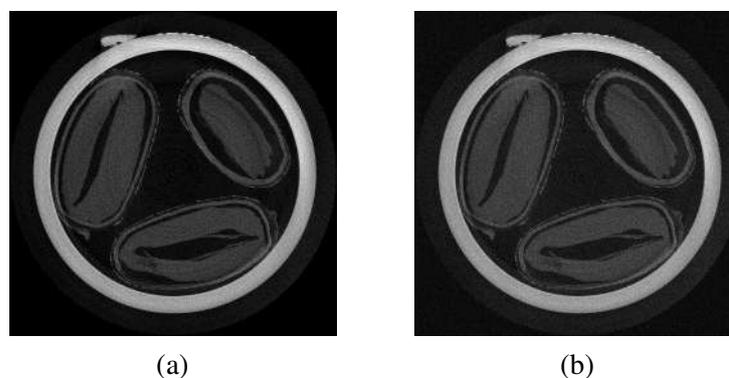
(d)

Figura 51 – Exemplo do resultado da aplicação do filtro de difusão anisotrópica aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (51a), à fatia tomográfica após adição de ruído Gaussiano (51b), ao ROI fatia da tomográfica ruidosa (51c) e à fatia tomográfica após a aplicação do filtro (51d).



B.1.2 Resultado do Filtro *Non-local Means*

Figura 52 – Exemplo do resultado da aplicação do filtro *non-local means* aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-mansão (52a), à fatia tomográfica após adição de ruído Gaussiano (52b), ao ROI fatia da tomográfica ruidosa (52c) e à fatia tomográfica após a aplicação do filtro (52d).



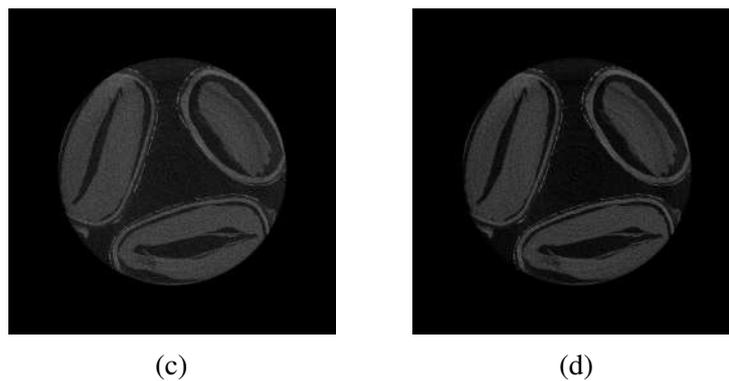
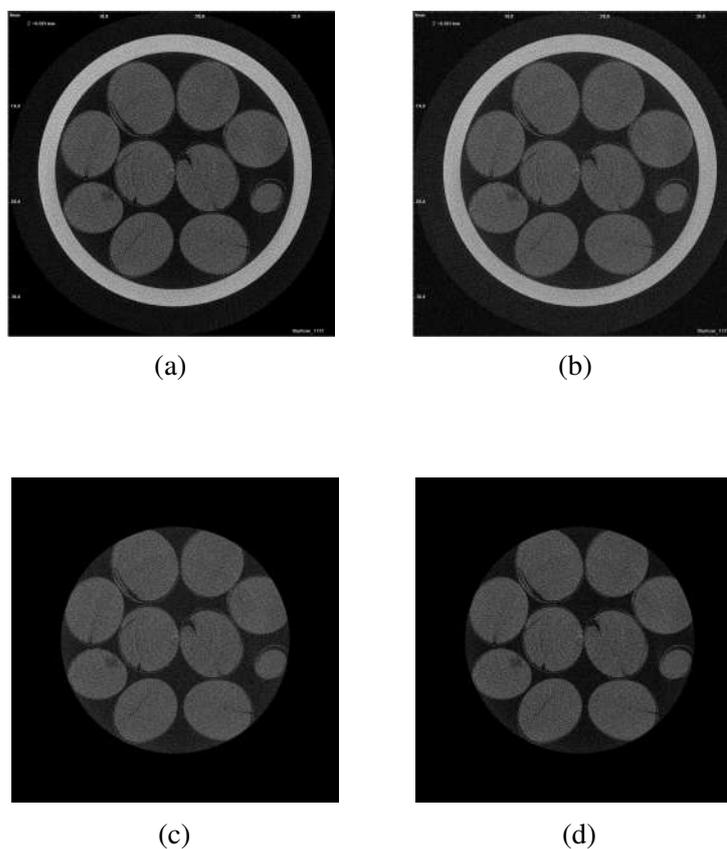


Figura 53 – Exemplo do resultado da aplicação do filtro *non-local means* aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (53a), à fatia tomográfica após adição de ruído Gaussiano (53b), ao ROI fatia da tomográfica ruidosa (53c) e à fatia tomográfica após a aplicação do filtro (53d).



B.1.3 Resultado do Filtro Gaussiano

Figura 54 – Exemplo do resultado da aplicação do filtro Gaussiano aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-manso (54a), à fatia tomográfica após adição de ruído Gaussiano (54b), ao ROI fatia da tomográfica ruidosa (54c) e à fatia tomográfica após a aplicação do filtro (54d).

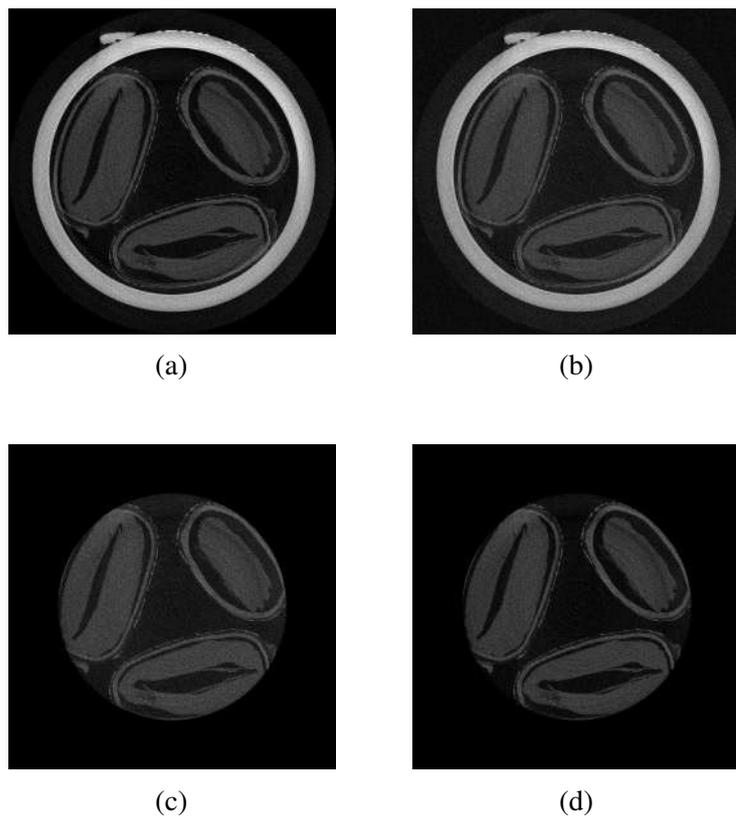
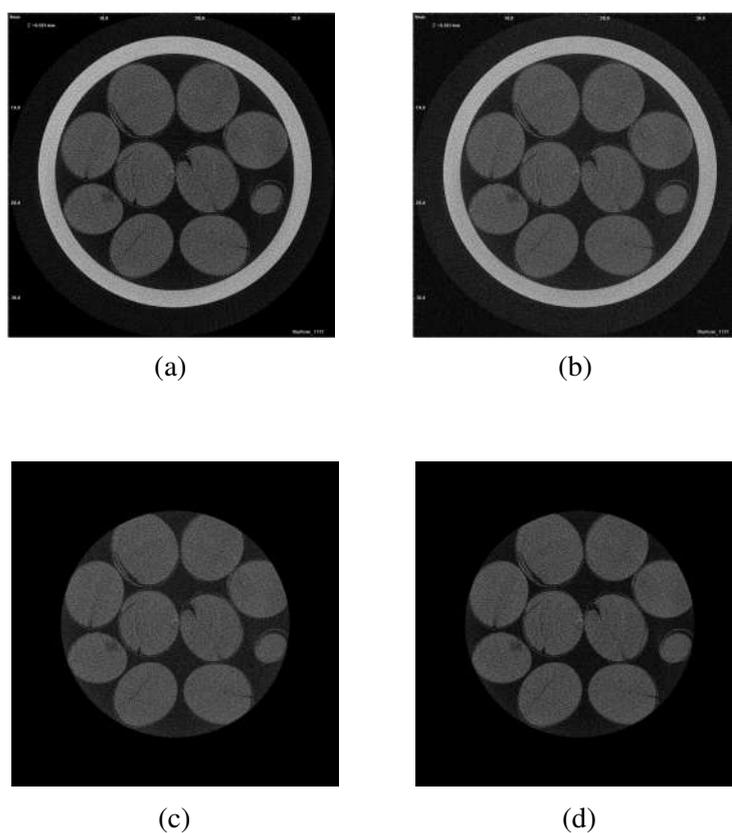


Figura 55 – Exemplo do resultado da aplicação do filtro Gaussiano aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (55a), à fatia tomográfica após adição de ruído Gaussiano (55b), ao ROI fatia da tomográfica ruidosa (55c) e à fatia tomográfica após a aplicação do filtro (55d).



B.1.4 Resultado do Filtro Passa-banda Ideal

Figura 56 – Exemplo do resultado da aplicação do filtro passa-banda ideal aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de pinhão-manso (56a), à fatia tomográfica após adição de ruído Gaussiano (56b), ao ROI fatia da tomográfica ruidosa (56c) e à fatia tomográfica após a aplicação do filtro (56d).

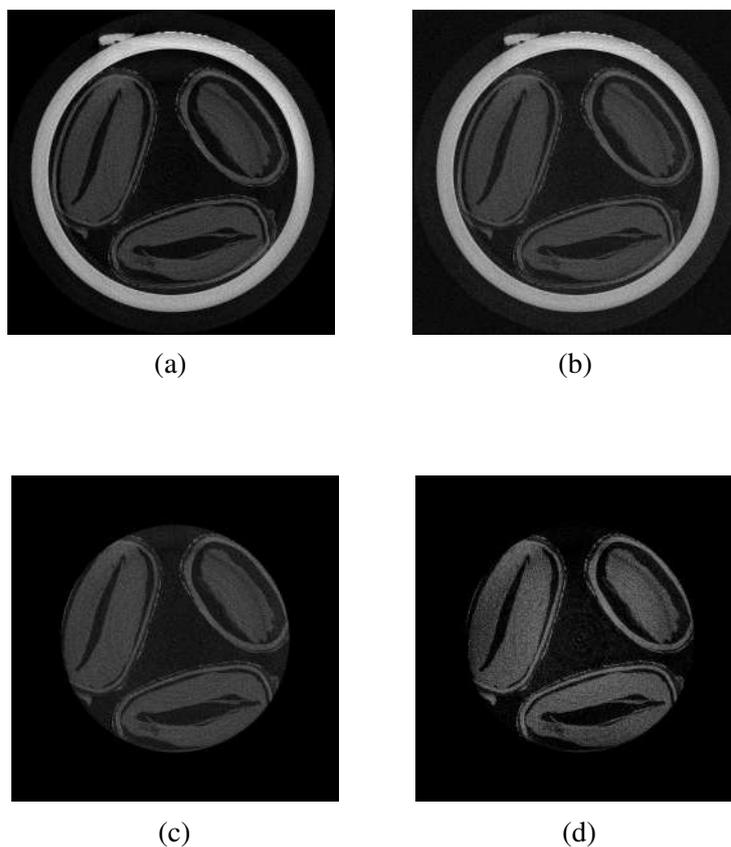
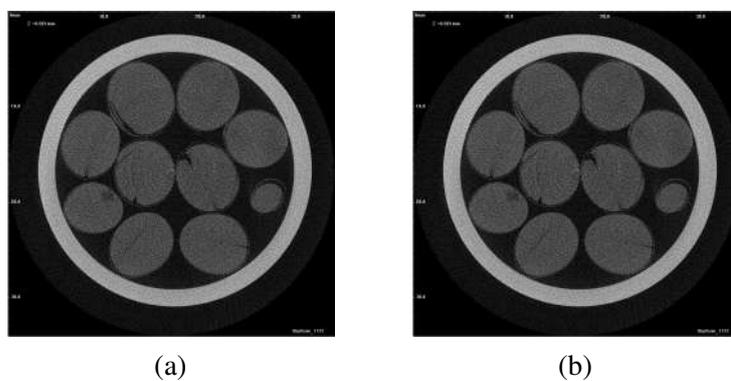
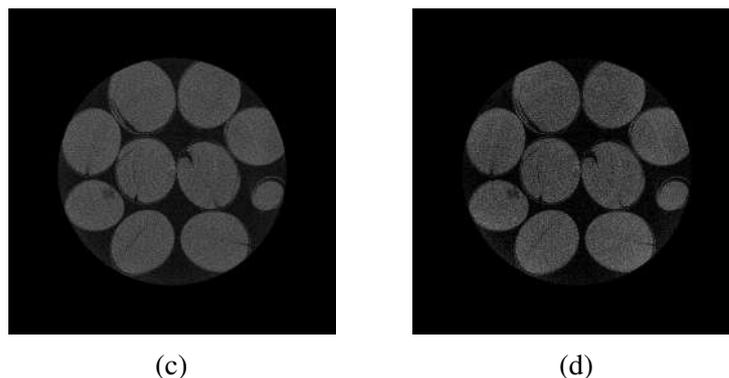


Figura 57 – Exemplo do resultado da aplicação do filtro passa-banda ideal aplicado sobre o ruído Gaussiano referente à fatia tomográfica da semente de soja (57a), à fatia tomográfica após adição de ruído impulsivo (57b), ao ROI fatia da tomográfica ruidosa (57c) e à fatia tomográfica após a aplicação do filtro (57d).





B.2 Segmentação

B.2.1 Resultado da Segmentação de Limiarização

Figura 58 – Exemplo de segmentação pela técnica de limiarização aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de pinhão-manso (58a), à fatia tomográfica binarizada da técnica de segmentação (58b) e à conjunção entre as duas fatias tomográficas (58c).

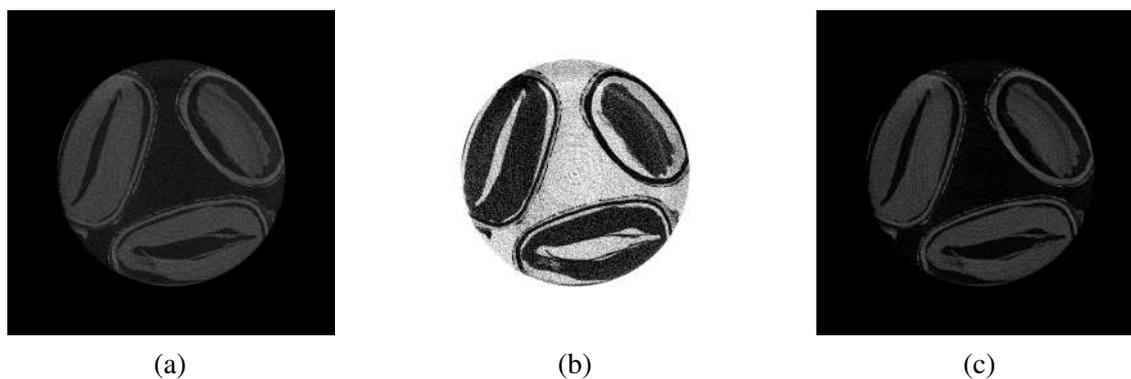
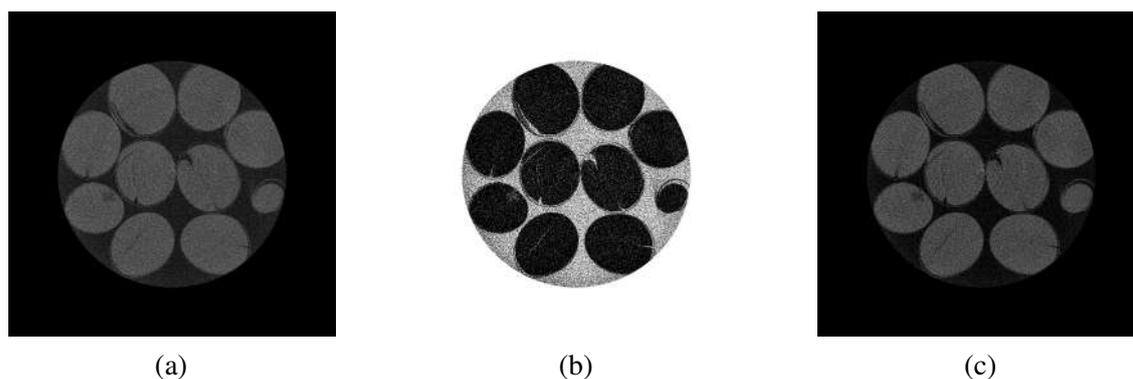


Figura 59 – Exemplo de segmentação pela técnica de limiarização aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de soja (59a), à fatia tomográfica binarizada da técnica de segmentação (59b) e à conjunção entre as duas fatias tomográficas (59c).



B.2.2 Resultado da Segmentação Otsu

Figura 60 – Exemplo de segmentação pela técnica de Otsu aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de pinhão-manso (60a), à fatia tomográfica binarizada da técnica de segmentação (60b) e à conjunção entre as duas fatias tomográficas (60c).

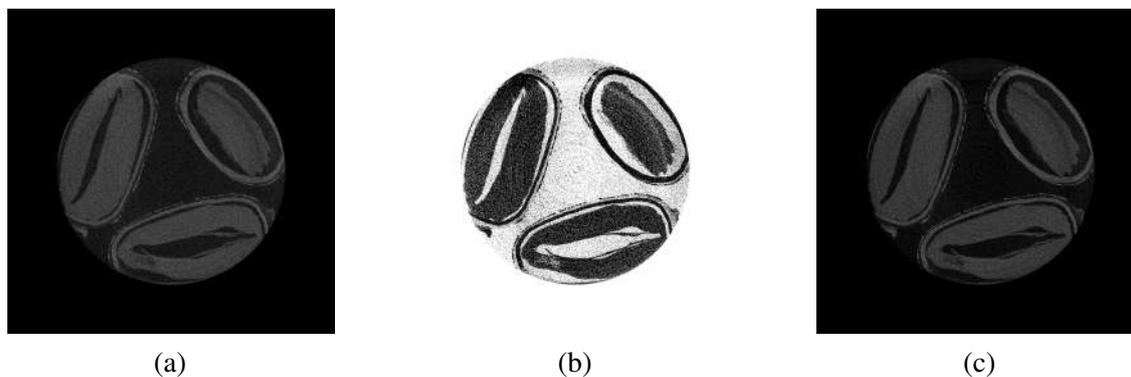
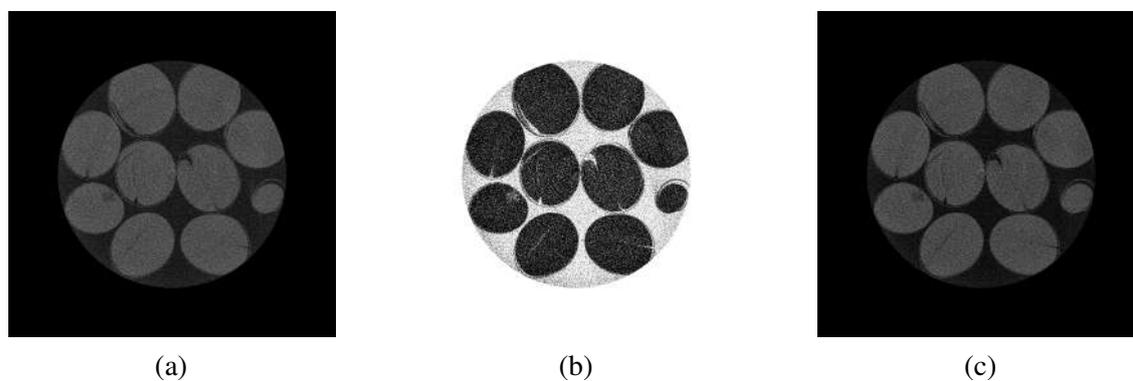


Figura 61 – Exemplo de segmentação pela técnica de Otsu aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de soja (61a), à fatia tomográfica binarizada da técnica de segmentação (61b) e à conjunção entre as duas fatias tomográficas (61c).



B.2.3 Resultado da Segmentação em Grafo

Figura 62 – Exemplo de processo de equalização do histograma a partir da fatia tomográfica de pinhão-mansó suavizada com o filtro Gaussiano (62a) e o seu histograma (62b), juntamente com o resultado da fatia tomográfica equalizada (62c) e o seu histograma (62d).

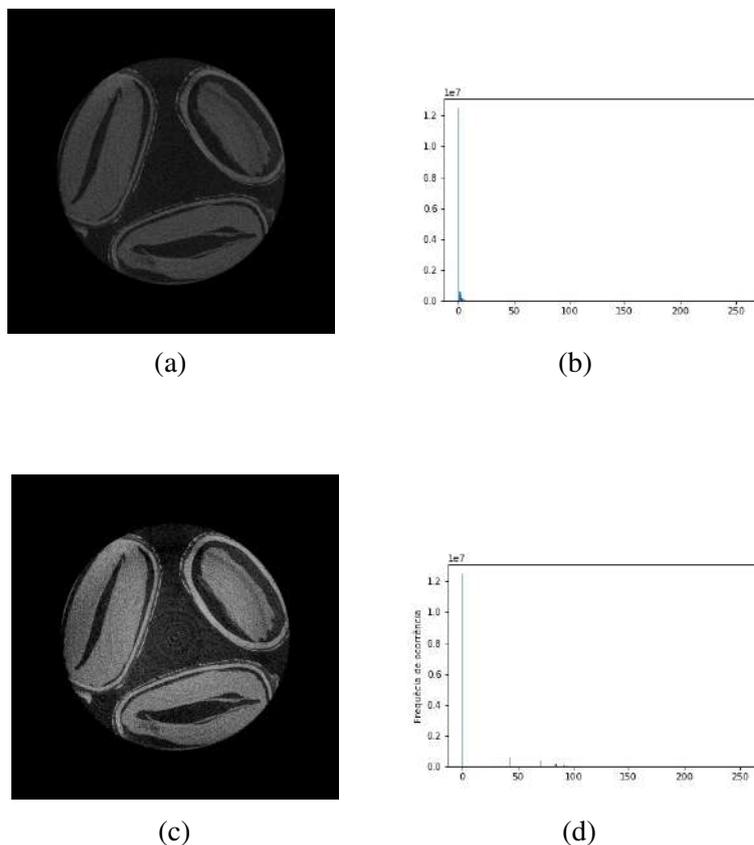
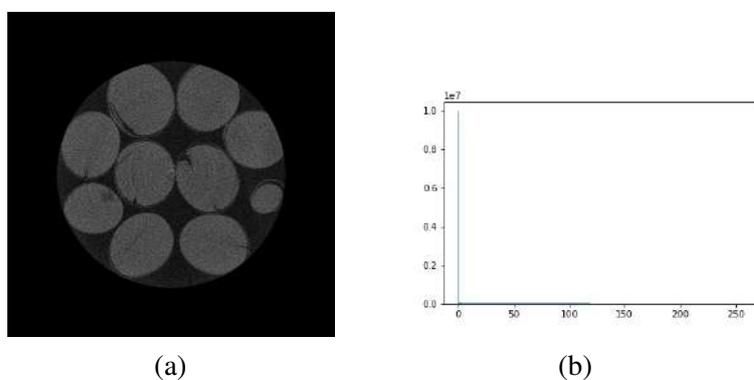


Figura 63 – Exemplo de processo de equalização do histograma a partir da fatia tomográfica de soja suavizada com o filtro Gaussiano (63a) e o seu histograma (63b), juntamente com o resultado da fatia tomográfica equalizada (63c) e o seu histograma (63d).



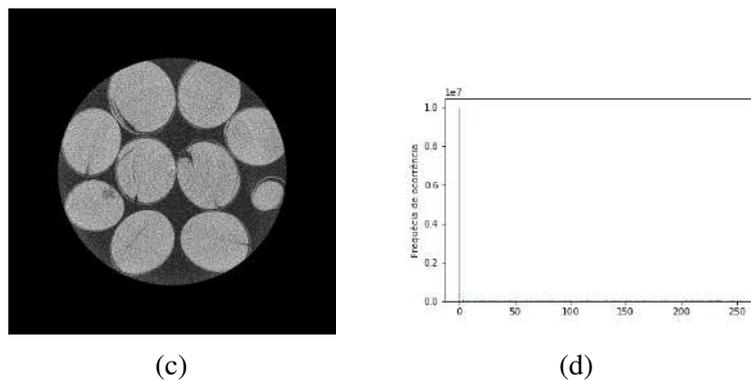


Figura 64 – Exemplo de segmentação pela técnica grafo, aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de pinhão-manso (64a), ao resultado da fatia tomográfica binarizada da segmentação (64b) e à conjunção entre as duas fatias tomográficas (64c).

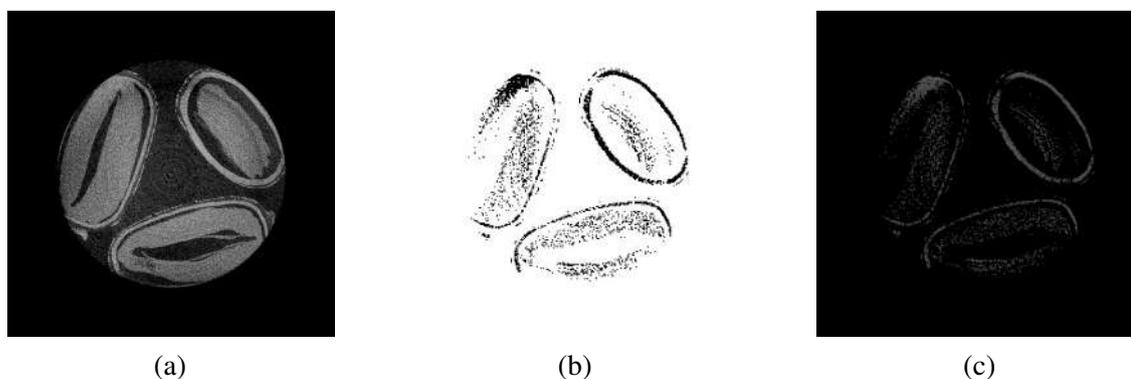
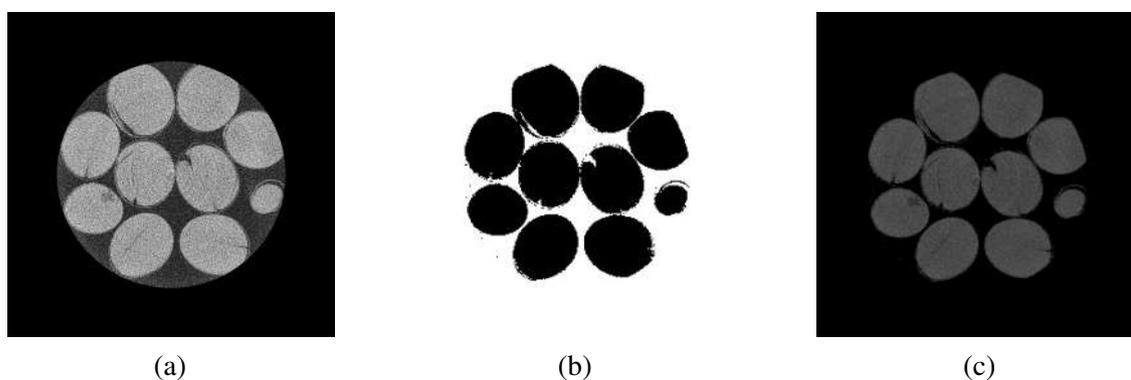


Figura 65 – Exemplo de segmentação pela técnica grafo aplicado em fatia tomográfica após o filtro Gaussiano referente à semente de Soja (65a), ao resultado da fatia tomográfica binarizada da segmentação (65b) e à conjunção entre as duas fatias tomográficas (65c).



B.3 Extração de Características

B.3.1 Extração de Características pela Técnica de HOG

Figura 66 – Exemplo de extração de característica do método HOG aplicado na fatia tomográfica referente à semente de pinhão-manso.

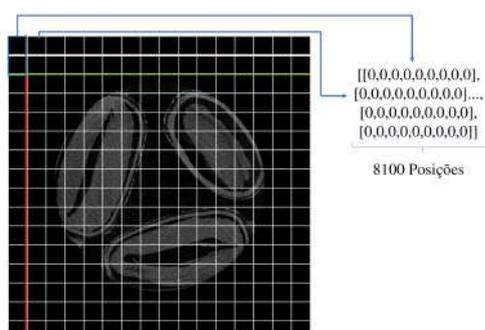
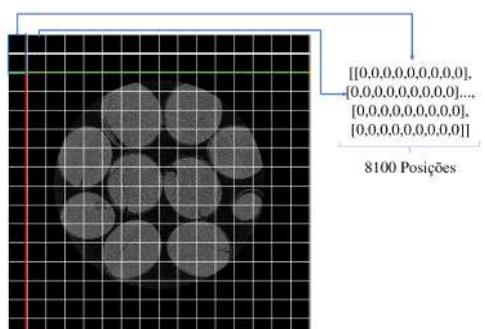


Figura 67 – Exemplo de extração de característica do método HOG aplicado na fatia tomográfica referente à semente de soja.



B.3.2 Extração de Características pela Técnica de Hu

Figura 68 – Exemplo de extração de característica do método momentos invariantes de Hu aplicado na fatia tomográfica referente à semente de pinhão-manso.

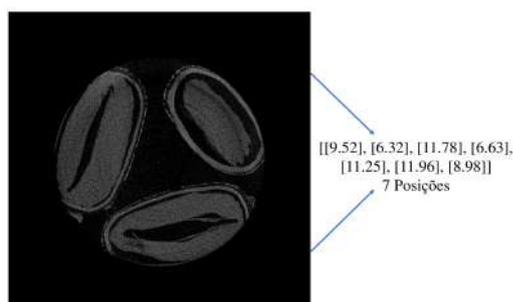
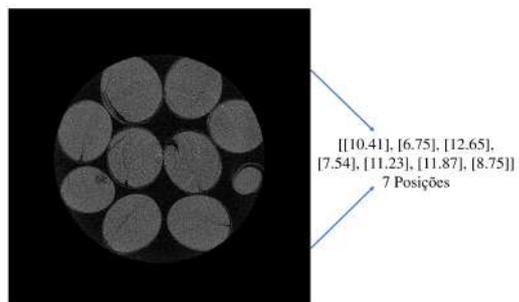


Figura 69 – Exemplo de extração de característica do método momentos invariantes de Hu aplicado na fatia tomográfica referente à semente de Soja.



APÊNDICE C

RESULTADOS DAS ANÁLISES DOS CLASSIFICADORES NAÏVE BAYES E SVM

C.1 Experimentos aplicados para uma base de dados com 70% treinamento e 30% teste

Tabela 7 – Resultados dos experimentos aplicados para uma base de dados com 70% treinamento e 30% teste usando o classificador Naïve Bayes.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,95	0,61	0,75	31	0,82
Girassol defeituosa	0,90	0,73	0,81	37	
Pinhão-manso	0,83	0,91	0,87	33	
Pinhão-manso defeituosa	0,79	0,89	0,84	35	
Soja	0,84	0,70	0,76	37	
Soja defeituosa	0,59	0,91	0,71	33	
Imagem Composta	1,00	0,97	0,99	38	

Tabela 8 – Resultados dos experimentos aplicados para uma base de dados com 70% treinamento e 30% teste usando o classificador SVM.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,96	0,81	0,88	31	0,90
Girassol defeituosa	0,90	0,97	0,94	37	
Pinhão-manso	0,94	0,94	0,94	33	
Pinhão-manso defeituosa	1,00	0,86	0,92	35	
Soja	0,81	0,81	0,81	37	
Soja defeituosa	0,72	0,88	0,79	33	
Imagem Composta	1,00	1,00	1,00	38	

C.2 Experimentos aplicados para uma base de dados com 60% treinamento e 40% teste

Tabela 9 – Resultados dos experimentos aplicados para uma base de dados com 60% treinamento e 40% teste usando o classificador Naïve Bayes.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,86	0,70	0,78	44	0,79
Girassol defeituosa	0,91	0,65	0,76	46	
Pinhão-manso	0,86	0,88	0,87	43	
Pinhão-manso defeituosa	0,71	0,93	0,80	42	
Soja	0,77	0,67	0,72	49	
Soja defeituosa	0,60	0,79	0,68	52	
Imagem Composta	1,00	0,94	0,97	49	

Tabela 10 – Resultados dos experimentos aplicados para uma base de dados com 60% treinamento e 40% teste usando o classificador SVM.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,86	0,70	0,78	44	0,79
Girassol defeituosa	0,91	0,65	0,76	46	
Pinhão-manso	0,86	0,88	0,87	43	
Pinhão-manso defeituosa	0,71	0,93	0,80	42	
Soja	0,77	0,67	0,72	49	
Soja defeituosa	0,60	0,79	0,68	52	
Imagem Composta	1,00	0,94	0,97	49	

C.3 Experimentos aplicados para uma base de dados com 50% treinamento e 50% teste

Tabela 11 – Resultados dos experimentos aplicados para uma base de dados com 50% treinamento e 50% teste usando o classificador Naïve Bayes.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,86	0,59	0,70	54	0,80
Girassol defeituosa	0,83	0,74	0,78	61	
Pinhão-manso	0,96	0,86	0,91	57	
Pinhão-manso defeituosa	0,64	0,98	0,77	49	
Soja	0,77	0,64	0,70	58	
Soja defeituosa	0,66	0,81	0,73	64	
Imagem Composta	1,00	0,98	0,99	63	

Tabela 12 – Resultados dos experimentos aplicados para uma base de dados com 50% treinamento e 50% teste usando o classificador SVM.

Tipos de sementes	Precisão	Revocação	<i>F1-Score</i>	Suporte	Acurácia
Girassol	0,91	0,80	0,85	54	0,87
Girassol defeituosa	0,97	0,92	0,94	61	
Pinhão-manso	0,98	0,89	0,94	57	
Pinhão-manso defeituosa	0,89	0,82	0,85	49	
Soja	0,75	0,76	0,75	58	
Soja defeituosa	0,68	0,88	0,77	64	
Imagem Composta	1,00	1,00	1,00	63	