

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA**

FLÁVIO DA SILVA WALTZ

**SEGMENTAÇÃO DOS OSSOS DO JOELHO A PARTIR DE IMAGENS DE
TOMOGRAFIA COMPUTADORIZADA**

DISSERTAÇÃO

**CURITIBA
2020**

FLÁVIO DA SILVA WALTZ

**SEGMENTAÇÃO DOS OSSOS DO JOELHO A PARTIR DE IMAGENS DE
TOMOGRAFIA COMPUTADORIZADA**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Tecnológica Federal do Paraná como requisito para obtenção do título de “Mestre em Ciências” – Área de Concentração: Engenharia Biomédica.

Orientador: Prof. Dr. João Antônio Palma Setti

Co-Orientador: Prof. Dr. Francisco Itamarati Secolo Ganacim

CURITIBA
2020

Dados Internacionais de Catalogação na Publicação

Waltz, Flávio da Silva

Segmentação dos ossos do joelho a partir de imagens de tomografia computadorizada [recurso eletrônico] / Flávio da Silva Waltz. -- 2020.

1 arquivo eletrônico (119 f.): PDF; 5,71 MB.

Modo de acesso: World Wide Web.

Texto em inglês com resumo em português.

Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Biomédica. Área de Concentração: Engenharia Biomédica, Curitiba, 2020.

Bibliografia: f. 115-119.

1. Engenharia biomédica - Dissertações. 2. Hounsfield, Godfrey, 1919-. 3. Tomografia. 4. Joelhos. 5. Ossos. 6. Reconstrução de imagens. 7. Segmentação de imagens. 8. Imagem tridimensional. 9. Lógica de limite. 10. Processamento de imagens - Técnicas digitais. 11. Modelos matemáticos. I. Setti, João Antônio Palma, orient. II. Ganacim, Francisco Itamarati Secolo, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Biomédica. IV. Título.

CDD: Ed. 23 -- 610.28

Biblioteca Central do Câmpus Curitiba - UTFPR
Bibliotecária: Luiza Aquemi Matsumoto CRB-9/794

TERMO DE APROVAÇÃO DE DISSERTAÇÃO Nº150

A Dissertação de Mestrado intitulada “**SEGMENTAÇÃO DOS OSSOS DO JOELHO A PARTIR DE IMAGENS DE TOMOGRAFIA COMPUTADORIZADA**”, defendida em sessão pública pelo candidato Flávio da Silva Waltz, no dia 12 de Agosto de 2020, foi julgada para a obtenção do título de Mestre em Ciências, área de concentração Engenharia Biomédica, Linha de pesquisa Física Médica e aprovada em sua forma final, pelo Programa de Pós-Graduação em Engenharia Biomédica.

BANCA EXAMINADORA:

Prof. Dr Francisco Itamarati Secolo Ganacim (Presidente) – UTFPR

Prof. Dr. Leyza Elmeri Baldo Dorini– UTFPR

Prof. Dr. Leandro Moraes Valle Cruz – Casa da Moeda de Portugal

A via original deste documento encontra-se arquivada na Secretaria do Programa, contendo a assinatura da Coordenação após a entrega da versão corrigida do trabalho.

Curitiba, 02 de novembro de 2020.

Carimbo e Assinatura do(a) Coordenador(a) do Programa

AGRADECIMENTOS

Agradeço aos meus pais e à minha irmã, que, como sempre, foram uma fonte inesgotável de apoio e carinho.

Agradeço aos meus amigos e amigas, que me ajudam a superar ou a esquecer momentaneamente as dificuldades da vida.

Agradeço ao professor João Setti pelo incentivo constante e à professora Nara Bobko pela disposição para ajudar quando e como necessário.

Agradeço, especialmente, ao professor Francisco Ganacim, que me ensinou tanto em tão pouco tempo e que foi tão paciente enquanto me motivou a continuar aprendendo. Em nossas várias conversas aprendi muito mais do que aquilo sobre o que escrevi nesta dissertação.

RESUMO

WALTZ, Flávio. **Segmentação dos ossos do joelho a partir de imagens de tomografia computadorizada**. 2020. 119 p. Dissertação – Programa de Pós-Graduação em Engenharia Biomédica, Universidade Tecnológica Federal do Paraná. Curitiba, 2020.

A segmentação de estruturas anatômicas a partir de imagens médicas, como a tomografia computadorizada, tem sido aplicada no aperfeiçoamento de práticas como o planejamento cirúrgico, a fabricação de próteses, a realização de simulações e mais. Na área ortopédica, modelos 3d de ossos podem ser utilizados, por exemplo, na fabricação de guias e implantes personalizados.

Extrair precisamente elementos complexos de uma imagem não é uma tarefa simples. A maioria das pesquisas relacionadas propõe métodos para a segmentação de uma única estrutura anatômica. Nesta pesquisa, decidiu-se testar as dificuldades referentes à segmentação da superfície dos quatro ossos que constituem a articulação do joelho (fêmur, patela, tíbia e fíbula) a partir de imagens de tomografia computadorizada e das unidades Hounsfield.

O método proposto consiste em uma sequência de processamento que se inicia com a reamostragem dos dados, que são, então, pré-segmentados por *global thresholding* com limiar baseado no valor proposto pela literatura para segmentação de ossos: 200 UH. Em seguida, as descontinuidades das malhas obtidas, quando presentes, são corrigidas através de fechamento morfológico, e objetos indesejados, quando presentes, são removidos por erosão morfológica. Finalmente, os modelos são segmentados por *Active Contour Without Edges* executado por operadores morfológicos. Quatro estudos de caso com quatro indivíduos diferentes foram realizados através deste método.

Os resultados obtidos mostram que o método proposto é capaz de segmentar e gerar os modelos 3d dos quatro ossos do joelho, permitindo que cada um destes seja manipulado individualmente se necessário. Porém, a segmentação dos ossos com base nas unidades Hounsfield não gerou o resultado esperado em três dos quatro estudos de caso, dos quais apenas um teve seus ossos segmentados corretamente com a aplicação de um limiar igual a 200 UH durante a pré-segmentação por *global thresholding*. Nos demais casos, o limiar teve que ser reduzido para que a malha dos ossos fosse segmentada como esperado.

Palavras-chave: Segmentação de imagens; Unidades Hounsfield; Tomografia Computadorizada; *Active Contour Without Edges*.

ABSTRACT

WALTZ, Flávio. **Segmentation of the knee bones from computed tomography imaging**. 2020. 119 p. Dissertation – Graduate Program in Biomedical Engineering, Federal University of Technology - Paraná. Curitiba, 2020.

The segmentation of anatomical structures based on medical images, such as computed tomography, has been applied to improve practices such as surgical planning, prosthesis manufacturing, simulations and more. In the orthopedic area, 3d bone models can be used, for example, in the manufacture of personalized guides and implants.

Precisely extracting complex elements from an image is not a simple task. Most related research proposes methods for segmenting a single anatomical structure. In this research, it was decided to test the difficulties related to the segmentation of the surface of the four bones that constitute the knee joint (femur, patella, tibia and fibula) using computed tomography images and the Hounsfield units.

The proposed method consists of a processing sequence that begins with the resampling of the data, which are then pre-segmented by global thresholding with a chosen threshold based on the value proposed by the literature for bone segmentation: 200 HU. Then, the discontinuities of the obtained meshes, when present, are corrected through morphological closure, and undesirable objects, when present, are removed by morphological erosion. Finally, the models are segmented by Active Contour Without Edges executed by morphological operators. Four case studies with four different individuals were carried out using this method.

The results obtained show that the proposed method is capable of segmenting and generating 3d models of the four knee bones, allowing each one to be manipulated individually if necessary. However, the bone segmentation based on Hounsfield units did not generate the expected result in three of the four case studies, of which only one had its bones correctly segmented with the application of a threshold equal to 200 HU during pre-segmentation by global thresholding. In all other cases, the threshold had to be lowered so that the bone mesh was segmented as expected.

Key-words: Image Segmentation; Hounsfield Units; Computed Tomography; *Active Contour Without Edges*.

LISTA DE FIGURAS

Figura 1 – Sistema de TC da General Electric e seção transversal de uma cabeça humana..	20
Figura 2 – Modo de escaneamento paralelo e modo de leque, respectivamente.....	22
Figura 3 – Reconstrução da seção transversal.	23
Figura 4 – Imagem de TC de um joelho humano na qual são mostrados três pontos com intensidades diferentes (valores entre colchetes).	24
Figura 5 – Exemplos de áreas beneficiadas pelo processamento de imagens digitais.. .	27
Figura 6 – Processamento de nível baixo. À esquerda, a imagem original, no centro, a imagem após operação de aumento de nitidez e, à direita, a imagem após aplicação de um filtro de média de tamanho 9x9 pixels	28
Figura 7 –Processamento de nível médio. À esquerda, a imagem original, à direita, a imagem após aplicação de um processo de classificação.	29
Figura 8 – (a) Imagem original. (b) Operação aritmética: gradiente de Sobel. (c) Operação pontual: negativo da imagem. (d) Operação geométrica: rotação da imagem.	30
Figura 9 – Amostragem de um sinal contínuo unidimensional	32
Figura 10 – Vizinhança de um pixel no ponto (x,y).....	35
Figura 11 – Aplicação de um kernel de tamanho 3x3 sobre uma vizinhança de mesmo tamanho em uma imagem.	37
Figura 12 – Dois filtros de média de tamanho 3 x 3.	38
Figura 13 – Imagem original de tamanho 500x500 pixels (canto superior esquerdo) e imagens suavizadas por filtro de média de tamanho $m = 3, 5, 9, 15$ e 35 , respectivamente.....	40
Figura 14 – Amostragem e reconstrução de um sinal.	41
Figura 15 – (a) Imagem original, na qual um quadrado destaca a região mostrada nas imagens seguintes após interpolação (b) por vizinho mais próximo, (c) bilinear e (d) bicúbica, após aumento da imagem em 1200%..	43
Figura 16 – À esquerda: imagem original com ruído salt-and-pepper; no centro: imagem após aplicação de filtro de média de tamanho $m = 3$; à direita: imagem após aplicação de filtro de mediana de tamanho $m = 3$	44

Figura 17 – Difusão Anisotrópica e bordas detectadas na imagem após a difusão. (a) Imagem original. Número de iterações: (b) 100, (c) 200, (d) 400, (e) 1000 iterações.	45
Figura 18 – Desfoque Gaussiano e bordas detectadas na imagem após o desfoque. (a) Imagem original. Tamanho da máscara: (b) 3x3, (c) 15x15, (d) 25x25, (e) 35x35..	46
Figura 19 – Comparação entre o método de Perona e Malik, à esquerda, e a função de Tukey, à direita, após 500 iterações. As imagens na linha de baixo mostram as bordas identificadas nas imagens após o processamento.....	47
Figura 20 – Imagem binária sendo sondada por um ES quadrado.	48
Figura 21 – Erosão morfológica.	49
Figura 22 - Dilatação morfológica.....	50
Figura 23 – Abertura e fechamento morfológico.	52
Figura 24 – Representações ideais dos modelos de borda. Da esquerda para direita: step edge, ramp edge e roof edge.....	54
Figura 25 – Filtro (Laplaciano) para detecção de pontos isolados.	54
Figura 26 – Filtros para detecção de linhas. Na fileira de baixo são mostradas a imagem original (à esquerda) e os resultados gerados pelos filtros imediatamente acima das demais imagens.	55
Figura 27 – Operadores de Sobel, utilizados para detecção de bordas horizontais, verticais e diagonais, respectivamente.	56
Figura 28 – Posições de z.	57
Figura 29 – Operadores de Sobel. Imagem original e os resultados, cada um obtido através da máscara ao seu lado.	57
Figura 30 – Segmentação por contorno ativo com operadores morfológicos. São mostradas imagens após: 25, 50, 75, 100, 125, 150, 175 e 200 iterações, respectivamente.	59
Figura 31 – Segmentação realizada no software InVesalius 3.1. Os artefatos estão destacados por elementos vermelhos.	60
Figura 32 – Lookup table original do algoritmo Marching Cubes.	62
Figura 33 – Superfícies geradas pelo algoritmo clássico do Marching Cubes e pelo método de Lewiner et al.	63

Figura 34 – Ossos da articulação do joelho. Extraído de Color atlas of anatomy. A photographic study of the human body.	66
Figura 35 – Sequência de processamento proposta.	68
Figura 36 – Distância entre pixels da imagem do Indivíduo 01.	72
Figura 37 – Imagem original (esquerda) e imagem reamostrada (direita).	73
Figura 38 – Imagem de entrada e após 50, 250, 500 e 750 iterações de difusão anisotrópica, respectivamente.	75
Figura 39 – Segmentação por global thresholding. À esquerda, duas fatias da imagem de entrada, à direita, os respectivos resultados do processo de segmentação por global thresholding.	76
Figura 40 – Classificação dos objetos da imagem segmentada. Cada uma das estruturas classificadas é representada por um nível diferente de cinza.	77
Figura 41 – Classificação de estruturas por diferentes elementos estruturantes.	78
Figura 42 – Demonstração do processo de classificação e separação dos objetos da imagem.	79
Figura 43 – Histograma da imagem após o processo de classificação.	80
Figura 44 – Descontinuidades nas superfícies das ROI do Indivíduo 01. Malhas geradas pelo algoritmo Marching Cubes (Lewiner et al., 2012).	81
Figura 45 – Superfícies das ROI do Indivíduo 01 antes (fileira de cima) e depois do fechamento morfológico.	82
Figura 46 – Fêmur do Indivíduo 01, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	84
Figura 47 – Patela do Indivíduo 01, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	84
Figura 48 – Tíbia do Indivíduo 01, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	84
Figura 49 – Fíbula do Indivíduo 01, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	85
Figura 50 – Ossos do joelho do Indivíduo 01 renderizados no Blender 3d.	86
Figura 51 – ROI do Indivíduo 02 classificadas e separadas.	88

Figura 52 – Visualização de parte do fêmur em uma das camadas da imagem. São mostradas a imagem original, e a imagem após 50 e 250 iterações de difusão anisotrópica, respectivamente.	88
Figura 53 – ROI do Indivíduo 02 classificadas após mudança no parâmetro do thresholding.....	89
Figura 54 – Superfícies das ROI do Indivíduo 02 depois do fechamento morfológico. São mostrados, em destaque, artefatos nos ossos e um buraco na fíbula.....	90
Figura 55 – Fêmur do Indivíduo 02, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	91
Figura 56 – Patela do Indivíduo 02, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	92
Figura 57 – Tíbia do Indivíduo 02, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	92
Figura 58 – Fíbula do Indivíduo 02, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. Os destaques, em vermelho, mostram as falhas na malha segmentada.	92
Figura 59 – Malhas do fêmur e da tíbia, respectivamente, após erosão morfológica para remoção de pequenos artefatos.	94
Figura 60 – Ossos do joelho do Indivíduo 02 renderizados no Blender 3d.....	95
Figura 61 – Malhas do fêmur e da tíbia, respectivamente, após pré-segmentação. As áreas destacadas no fêmur mostram dois grandes buracos e um artefato pode ser visto na malha da tíbia.	97
Figura 62 – ROI do Indivíduo 03 classificadas e separadas.....	98
Figura 63 – Superfícies das ROI do Indivíduo 03 depois do fechamento morfológico.	98
Figura 64 – Artefato conectado à malha da tíbia antes e depois do fechamento morfológico.	99
Figura 65 – Erosão morfológica da malha da tíbia. Tamanho do raio dos elementos estruturantes utilizados, da esquerda para a direita: 3, 5, 7 e 9 pixels.....	100
Figura 66 – Fêmur do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. O destaque, em vermelho, mostra parte da área interna do osso, também segmentada.	101

Figura 67 – Patela do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	101
Figura 68 – Tíbia do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. O destaque, em vermelho, mostra parte da área interna do osso, também segmentada.	102
Figura 69 – Fíbula do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	102
Figura 70 – Ossos do joelho do Indivíduo 03 renderizados no Blender 3d.....	104
Figura 71 – ROI do Indivíduo 04. Fêmur, tíbia e fíbula após primeira tentativa de pré-segmentação. Os contornos em vermelho destacam as falhas geradas nos modelos.	105
Figura 72 – Superfícies das ROI do Indivíduo 04 depois do fechamento morfológico. A patela não precisou ser filtrada morfológicamente.	106
Figura 73 – Fêmur do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. O destaque, em vermelho, mostra parte da área interna do osso, também segmentada.	107
Figura 74 – Patela do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	107
Figura 75 – Tíbia do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	107
Figura 76 – Fíbula do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.	108
Figura 77 – Ossos do joelho do Indivíduo 04 renderizados no Blender 3d.....	109

LISTA DE TABELAS

Tabela 1 – Estruturas do joelho, com base na Figura 24.....	67
Tabela 2 – Descrição dos indivíduos examinados.....	69
Tabela 3 – Características de aquisição das imagens de TC.	70
Tabela 4 – UH atribuídas para diferentes substâncias.....	71
Tabela 5 – Duração do processo de difusão anisotrópica das imagens do Indivíduo 01.	76
Tabela 6 – Duração do processo de segmentação das ROI do Indivíduo 01.....	85
Tabela 7 – Duração do processo de segmentação das ROI do Indivíduo 02.....	93
Tabela 8 – Duração do processo de fechamento morfológico do fêmur e da fíbula do Indivíduo 03.	100
Tabela 9 – Duração do processo de segmentação das ROI do Indivíduo 03.....	103
Tabela 10 – Duração do processo de segmentação das ROI do Indivíduo 04.....	108
Tabela 11 – Reamostragem dos dados.	110
Tabela 12 – Limiares aplicados durante a pré-segmentação por global thresholding..	111
Tabela 13 – Relação entre duração média do processamento e tamanho das imagens.	113

LISTA DE ABREVIATURAS E SIGLAS

2d	Bidimensional
3d	Tridimensional
ACR	<i>American College of Radiology</i>
ACWE	<i>Active Contour Without Edges</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
INTO	Instituto Nacional de Traumatologia e Ortopedia
NEMA	<i>National Electrical Manufacturers Association</i>
RM	Ressonância Magnética
ROI	<i>Regions of interest</i>
SE	<i>Structuring element</i>
TAC	Tomografia Axial Computadorizada
TC	Tomografia Computadorizada
UH	Unidades Hounsfield

SUMÁRIO

Capítulo 1 - INTRODUÇÃO.....	16
1.1 Objetivos da Pesquisa.....	18
1.1.1 Objetivo Geral	18
1.1.2 Objetivos Específicos	18
1.2 Estrutura do Trabalho	19
Capítulo 2 - TOMOGRAFIA COMPUTADORIZADA	20
2.1 Conceitos Fundamentais.....	20
2.1.1 Reconstrução da Imagem	23
2.1.2 Unidades Hounsfield	25
2.1.3 <i>Digital Imaging and Communications in Medicine</i>	26
Capítulo 3 - PROCESSAMENTO DE IMAGENS DIGITAIS	27
3.1 Introdução à Amostragem e Quantização de Imagens	31
3.1.1 Amostragem (<i>Sampling</i>).....	31
3.1.2 Quantização (<i>Quantization</i>)	32
3.2 Transformações de Intensidade e Filtragem Espacial	33
3.2.1 Vizinhança de <i>Pixels</i>	34
3.2.2 Filtragem Linear	36
3.2.3 Reconstrução de Imagens	41
3.2.4 Filtragem Não Linear	43
3.2.4.1 Filtro de Difusão Anisotrópica	44
3.2.5 Processamento Morfológico de Imagens	48
3.2.6 Segmentação de Imagens	53
3.2.7 <i>Marching Cubes</i>	60
Capítulo 4 - PYTHON	64
Capítulo 5 - OSSOS DA ARTICULAÇÃO DO JOELHO	66
Capítulo 6 - DESENVOLVIMENTO.....	68
6.1 Materiais e Métodos	69
6.2 Estudo de Caso: Indivíduo 01	71
6.2.1 Preparação dos Dados	71
6.2.2 Pré-Segmentação da Imagem	74

6.2.3	Filtragem Morfológica para Correção de Superfícies	80
6.2.4	Segmentação.....	83
6.2.5	Refinamento e exportação	85
6.3	Estudo de Caso: Indivíduo 02	87
6.3.1	Preparação dos Dados	87
6.3.2	Pré-segmentação.....	87
6.3.3	Filtragem Morfológica para Correção de Superfícies	90
6.3.4	Segmentação.....	91
6.3.5	Refinamento e Exportação	93
6.4	Estudo de Caso: Indivíduo 03	96
6.4.1	Preparação dos Dados	96
6.4.2	Pré-Segmentação	96
6.4.3	Filtragem Morfológica para Correção de Superfícies	98
6.4.4	Segmentação.....	101
6.4.5	Refinamento e Exportação	103
6.5	Estudo de Caso: Indivíduo 04	104
6.5.1	Preparação dos Dados	104
6.5.2	Pré-Segmentação	105
6.5.3	Filtragem Morfológica para Correção das Superfícies.....	106
6.5.4	Segmentação.....	106
6.5.5	Refinamento e exportação	108
Capítulo 7 - RESULTADOS E DISCUSSÕES.....		110
7.1	Preparação dos dados	110
7.2	Pré-segmentação.....	111
7.3	Filtragem Morfológica	112
7.4	Segmentação.....	112
7.5	Refinamento e Exportação	114
Capítulo 8 - CONCLUSÃO.....		115
8.1	Direções Futuras.....	116
REFERÊNCIAS BIBLIOGRÁFICAS		117

Capítulo 1 - INTRODUÇÃO

Segundo o Dr. Alan Mozella (2020), do Instituto Nacional de Traumatologia e Ortopedia (INTO), a principal causa de incapacidade física crônica é a osteoartrose dos joelhos, que acomete 12% da população mundial acima dos 60 anos. O Dr. Mozella afirma que nos casos mais graves o tratamento é dado por cirurgia de substituição articular por prótese total do joelho (Artroplastia Total do joelho) (INTO, 2020).

A Academia Americana de Cirurgiões Ortopédicos relata que mais de 500.000 pacientes têm seus joelhos degenerativos substituídos a cada ano nos Estados Unidos através de procedimentos que têm sido aperfeiçoados por cirurgias personalizadas projetadas especificamente para cada paciente (Wu et al., 2014).

A partir da obtenção de imagens tomográficas do joelho do paciente, por exemplo, um modelo tridimensional (3d) pode ser extraído e então utilizado para o planejamento cirúrgico. O uso da tecnologia na medicina, especialmente do processamento de imagens, otimiza o fluxo de trabalho e reduz custos, sendo de grande relevância para as práticas clínicas (Wu et al., 2014).

Desde o seu desenvolvimento, a tomografia computadorizada (TC) vem sendo aplicada no diagnóstico médico (Geiger, 1993). Através de cálculos matemáticos complexos, a TC é capaz de gerar imagens bidimensionais (2d) que podem ser analisadas, tratadas, arquivadas e reconstruídas para obtenção de imagens 3d, que permitem melhor entendimento de estruturas espaciais (Geiger, 1993).

Neste contexto, pesquisas recentes têm demonstrado as vantagens provenientes do processamento de imagens digitais, a partir do qual são gerados recursos que podem auxiliar práticas como planejamento cirúrgico, fabricação de próteses e manufatura aditiva (comumente chamada de impressão 3d), não somente através da TC, mas também da Ressonância Magnética (RM) (Trusty et al., 2018; Vukicevic et al., 2018; Coronel, Palacio e Rueda-Esteban, 2017).

Em aspectos gerais, o processamento de imagens digitais tem como principais aplicações: a melhoria de informação visual para a interpretação humana, e o processamento de dados de cenas para a percepção automática através de máquinas. Quanto às imagens médicas, o processamento de imagens digitais pode ser utilizado, por exemplo, para realce e segmentação (Gonzalez e Woods, 2006).

Na área ortopédica, especificamente na pesquisa relacionada ao esqueleto, o processamento de imagens pode ser utilizado para criação de simulações e modelos que

poderão auxiliar o planejamento de procedimentos como: realocação de fragmentos de fratura, fabricação de guias e produção de implantes precisos (Idram et al., 2017; Pinheiro e Alves, 2015).

Além das vantagens para a área médica, segundo a pesquisa de McMEnamin et. al. (2014), a impressão de modelos oriundos de imagens médicas representa uma alternativa às técnicas de ensino de anatomia tradicionais, largamente baseadas em dissecação de cadáveres, o que têm implicações financeiras e de saúde para aqueles que manipulam estes cadáveres.

Os modelos impressos a partir de imagens de TC possuem precisão comparável às amostras originais, além de representarem fielmente características como a cor da estrutura. Essa abordagem permite a produção rápida de várias cópias de qualquer espécime, em qualquer escala de tamanho, e pode ser implementada em locais onde o acesso aos cadáveres é restrito ou dificultado por questões éticas e culturais (McMenamin et. al., 2014).

Especialmente com base nas informações apresentadas nos dois parágrafos anteriores, espera-se que a presente pesquisa represente uma contribuição à comunidade científica e acadêmica. Os modelos gerados não poderão ser analisados quantitativamente a respeito de sua precisão e, portanto, não poderão ser destinados à aplicação médica. Porém, a metodologia proposta é capaz de gerar modelos de diferentes ossos a partir de imagens de TC em poucas horas, e os resultados podem ser processados para que tenham aspecto realista, como será demonstrado, ou impressos para fins diversos, como o ensino.

A metodologia proposta será aplicada às imagens de TC de quatro indivíduos. A obtenção das malhas dos objetos de interesse será realizada por técnicas de segmentação de imagens – *global thresholding* e *Active Contour Without Edges*. Durante a segmentação por *global thresholding*, será dada atenção especial à aplicabilidade das unidades Hounsfield para segmentação de ossos em imagens de TC. A correção das malhas, quando necessária, será feita por operadores morfológicos, especificamente o fechamento morfológico e a erosão morfológica. Ao final do processo, espera-se que as malhas geradas se assemelhem às superfícies dos objetos reais, sem descontinuidades ou quaisquer objetos estranhos conectados a elas.

Os resultados obtidos foram considerados satisfatórios na maioria dos casos estudados. Contudo, houve divergências relevantes entre estes, que variaram desde o limiar utilizado para o processo de segmentação até o método de correção das malhas. Ou seja, embora a metodologia tenha sido igualmente aplicada a todos os estudos de

caso, diferenças pontuais entre as imagens exigiram alterações de parâmetros específicos. Todos estes dados serão apresentados ao longo dos tópicos de desenvolvimento.

Os capítulos a seguir apresentam e explicam as técnicas empregadas no desenvolvimento desta pesquisa, cujo foco foi a segmentação das superfícies dos ossos que compõem a articulação do joelho. Além dos dados apresentados no tópico introdutório, discussões em ambiente acadêmico acerca das dificuldades inerentes à segmentação de estruturas anatômicas a partir de imagens médicas contribuíram largamente para a definição do escopo da pesquisa.

1.1 Objetivos da Pesquisa

1.1.1 Objetivo Geral

O objetivo geral desta pesquisa foi definido como o desenvolvimento de uma metodologia baseada em técnicas segmentação de imagens aplicadas à imagens de TC a partir das quais deverão ser obtidos modelos 3d dos ossos que compõem a articulação do joelho através de imagens de tomografia computadorizada.

1.1.2 Objetivos Específicos

- Propor uma metodologia com a qual seja possível obter os modelos 3d das superfícies da extremidade distal do fêmur, da extremidade proximal da tíbia, da extremidade proximal da fíbula e da patela a partir de imagens de tomografia computadorizada;
- identificar as dificuldades inerentes à segmentação de imagens de tomografia computadorizada com base nas unidades Hounsfield.

1.2 Estrutura do Trabalho

O Capítulo 2 apresentará informações sobre o desenvolvimento da tomografia computadorizada, incluindo os métodos de aquisição e formação das imagens. Em seguida, o Capítulo 3 abordará o processamento de imagens digitais, com foco nas técnicas utilizadas para o desenvolvimento desta pesquisa. O Capítulo 4 apresentará a linguagem de programação Python, e o Capítulo 5 mostrará brevemente os ossos da articulação do joelho humano. No Capítulo 6, serão mostrados os processos e resultados obtidos após a aplicação do método desenvolvido. No Capítulo 7 esses resultados serão comparados e discutidos, e no Capítulo 8 será dada a conclusão do trabalho juntamente com um direcionamento para pesquisas futuras.

Capítulo 2 - TOMOGRAFIA COMPUTADORIZADA



Os pioneiros na pesquisa e desenvolvimento da Tomografia Axial Computadorizada (TAC), criada no início da década de 1970, foram Godfrey Hounsfield (Hounsfield, 1973) e Allan Cormack (Cormack, 1980), o que lhes rendeu o Prêmio Nobel de Medicina no ano de 1979 (Gonzalez e Woods, 2006).

O contraste gerado pela TAC, especialmente entre tecidos moles e duros (Pinheiro e Alves, 2015), e a exibição da anatomia do paciente através de diferentes planos tornam a técnica excepcionalmente útil para a visualização da anatomia de diferentes regiões do corpo (Hendee e Ritenour, 2002). Essas e outras características fazem com que a criação da TC seja um dos mais importantes eventos na aplicação do processamento de imagem no diagnóstico médico (Gonzalez e Woods, 2006),

2.1 Conceitos Fundamentais

A tomografia computadorizada consiste no processo de criação da imagem de uma seção transversal do corpo humano utilizando dados coletados por milhares de feixes individuais de raios-X que são emitidos ao longo do objeto de estudo. Esses dados são processados por um computador e a seção computada é exibida em um monitor de vídeo (Anton e Rorres, 2001). A Figura 1 mostra um diagrama do sistema de TC da General Electric e fatia de uma cabeça humana obtida por esse sistema.

Figura 1 – Sistema de TC da General Electric e seção transversal de uma cabeça humana.



Fonte: Álgebra Linear com Aplicações (2001).

Na Figura 1 pode-se ver um paciente preparado para ter uma seção transversal de sua cabeça escaneada por um feixe de raios-X e, à direita, a imagem de uma cabeça humana gerada por múltiplas medidas de absorções de raios-X (Anton e Rorres, 2001).

Em exames de raio-X tradicionais, as imagens são obtidas através da projeção dos raios-X perpendicularmente ao plano da imagem, enquanto tomógrafos são construídos a partir de milhares de feixes muito finos de raios-X que ficam no plano da seção transversal (Anton e Rorres, 2001). Depois de passarem pela seção transversal, as intensidades dos feixes são medidas por um detector de raios-X, e os valores de atenuação obtidos de cada pequeno volume da imagem (denominado *voxel*) são utilizados para produzir uma representação numérica do objeto (Haaga et al., 1996). A técnica baseia-se na equação de atenuação dos raios-X, definida por

$$I = I_0 e^{-\mu L} \quad (2.1)$$

onde I_0 é a intensidade incidente de um feixe de raios-X sobre a superfície de um objeto de espessura L , I é a intensidade transmitida, e μ é o coeficiente de atenuação linear (Haaga et al., 1996).

Segundo Hendee e Ritenour (2002), se a radiação for interceptada por duas regiões com coeficientes de atenuação μ_1 e μ_2 , e espessura x_1 e x_2 , a transmissão dos raios-X é dada por

$$I = I_0 e^{-(\mu_1 x_1 + \mu_2 x_2)} \quad (2.2)$$

e se várias regiões (n) com vários coeficientes de atenuação linear estiverem no caminho dos raios-X, a transmissão é dada por

$$I = I_0 e^{-\sum_{i=1}^n \mu_i x_i} \quad (2.3)$$


onde $-\sum_{i=1}^n \mu_i x_i = (\mu_1 x_1 + \mu_2 x_2 + \dots + \mu_n x_n)$.

Ao longo dos anos os métodos de aquisição foram aperfeiçoados em diversos aspectos, que diminuiram muito o tempo de exame, a dose de radiação recebida pelo paciente, a interferência (*noise*) e aumentaram a resolução das imagens. Estes resultados

foram obtidos, por exemplo, através do aumento do número de detectores e de mudanças na forma de emissão dos raios-X (Haaga et al., 1996; Hendee e Ritenour, 2002).

A Figura 2 mostra dois métodos possíveis de escanear a seção transversal: o modo paralelo e o modo de leque (Anton e Rorres, 2001).

Figura 2 – Modo de escaneamento paralelo e modo de leque, respectivamente.



Fonte: Álgebra Linear com Aplicações (2001).

No modo paralelo, mostrado à esquerda na Figura 2, um único par de fonte e de detector de raios-X é transladado através do campo de visão que contém a seção transversal e uma grande quantidade de feixes paralelos é registrada. Em seguida, o par fonte e detector é girado por um pequeno ângulo e o registro de um novo conjunto de medidas é feito. Esse processo é repetido até que o número de medidas desejado seja alcançado (Anton e Rorres, 2001).

No modo de leque, mostrado à direita na Figura 2, uma única fonte de raios-X gera um leque de raios colimados cujas intensidades são medidas simultaneamente por detectores do outro lado do campo de visão. A fonte e o conjunto de detectores são girados por muitos ângulos, e um conjunto de medidas é tomado em cada ângulo até completar o escaneamento (Anton e Rorres, 2001).

No modo paralelo, utilizado no primeiro sistema comercial de TC para uso médico, desenvolvido em 1971, cada escaneamento levava cerca de cinco minutos e meio. No modo de leque, cada escaneamento leva aproximadamente 1 segundo (Anton e Rorres, 2001).

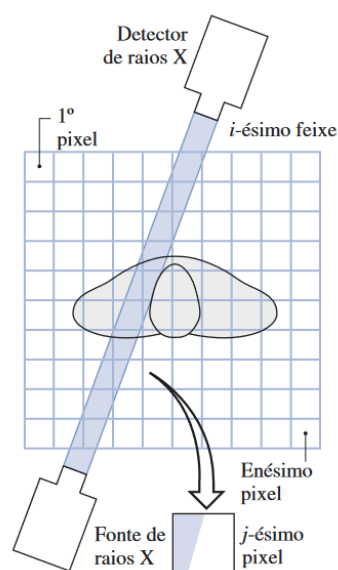
Problemas diferentes podem surgir nas imagens em decorrência de diversos fatores. Os artefatos, como são chamados, podem ser causados por disfunção do equipamento, podem estar relacionados ao paciente, a objetos com atenuação excepcionalmente alta ou baixa presentes na área examinada (próteses metálicas, por exemplo) e mais (Haaga et al., 1996).

No contexto desta pesquisa, o termo *artefato* será utilizado para designar objetos indesejáveis nas imagens processadas, sejam eles decorrentes das características apresentadas no parágrafo anterior ou referentes a uma parte do corpo dos indivíduos estudados que não pertence ao objeto de interesse da pesquisa. A fim de auxiliar o leitor, estes artefatos serão destacados em figuras ao longo do texto.

2.1.1 Reconstrução da Imagem

Os dados coletados pelos sensores, constituídos por muitas somas de raios individuais, precisam ser processados por algoritmos de reconstrução, responsáveis por transformar esses dados nas imagens transversais (Haaga et al., 1996; Gonzalez e Woods, 2006). A Figura 3 exemplifica o processo de reconstrução da seção transversal a partir de muitas medidas de feixes (Anton e Rorres, 2001).

Figura 3 – Reconstrução da seção transversal.




Fonte: Álgebra Linear com Aplicações (2001).

Na Figura 3, o campo de visão no qual está situada a seção transversal foi dividido em *pixels* quadrados (sendo um *pixel* um elemento pictográfico da imagem digitalizada). O objetivo da reconstrução é determinar a densidade dos raios-X de cada *pixel*. Após concluída essa etapa, as densidades dos *pixels* são reproduzidas em um monitor de vídeo, onde cada *pixel* é sombreado com um nível de cinza proporcional à sua densidade de raios-X (Anton e Rorres, 2001).

Como os diversos tecidos humanos têm densidades de raios-X diferentes, pode-se distinguir os diversos tecidos e órgãos na seção transversal na imagem gerada (Anton e Rorres, 2001). A Figura 4 exemplifica o que foi dito sobre as intensidades encontradas em uma imagem de TC.

Figura 4 – Imagem de TC de um joelho humano na qual são mostrados três pontos com intensidades diferentes (valores entre colchetes).



Fonte: adaptado de *Natural Knee Data* (2020).

A Figura 4 exibe como cada uma das estruturas destacadas na imagem apresenta um valor de intensidade diferente. A intensidade do ponto destacado no fêmur, por exemplo, equivale a 277 unidades Hounsfield, enquanto a intensidade na área escura, que representa o ar, equivale a -999 unidades Hounsfield (o conceito de unidades Hounsfield será abordado em mais detalhes no tópico seguinte).

Reconstruir a imagem de TC, em termos simples, significa encontrar o valor de μ para cada um dos elementos da matriz de dados (elementos da imagem) a ser gerada.

Contudo, como são obtidas milhares de projeções de raios para um único *scan*, é necessário resolver milhares de equações simultaneamente (Haaga et al., 1996).

A maioria dos fabricantes aplica o método de Retroprojeção Filtrada (*Filtered Backprojection*) para a reconstrução de imagens de TC. Esse algoritmo de reconstrução, também conhecido como método de convolução, usa uma equação integral unidimensional para a reconstrução de uma imagem 2d. Nesse método, uma função de *deblurring* é convolucionada com os dados de transmissão de raios-X para remover a maioria do desfoque (*blurring*) antes que os dados sejam retroprojetados. Uma das vantagens desse método é que a reconstrução ocorre enquanto os dados do exame são coletados, agilizando a formação da imagem (Hendee e Ritenour, 2002; Haaga et al., 1996).

2.1.2 Unidades Hounsfield

Os números obtidos após a reconstrução da imagem não representam os valores exatos do coeficiente de atenuação, sendo, na verdade, coeficientes de atenuação linear relativos (Haaga et al., 1996). Para que seja possível comparar a composição entre tecidos, um sistema que relaciona os coeficientes de atenuação linear dos raios-X aos números de TC foi criado, e essa relação é descrita por

$$\text{Número de TC} = \frac{K(\mu - \mu_w)}{\mu_w} \quad (2.4)$$

onde μ_w é igual ao coeficiente de atenuação da água, μ é o coeficiente de atenuação do *pixel*, e à K foi atribuído o valor 1000 (Haaga et al., 1996).

Em homenagem à Godfrey Hounsfield, as unidades de TC são chamadas de unidades Hounsfield (UH), sendo atribuído valor -1000 para o ar, valor 0 para água e o osso denso possui valor $+1000$ (Hendee e Ritenour, 2002).

Além dos valores atribuídos para ar, água e osso denso, na escala de UH, o tecido adiposo é representado por valores entre -300 e -100 UH, o tecido muscular está entre 10 e 70 UH, e ossos são representados por valores maiores que 200 UH (Yoo, 2004).

Os dados necessários para a conversão dos valores obtidos durante o exame em Números de TC estão disponíveis no *header* das imagens médicas. Esse é um recurso garantido pela padronização na forma de distribuição e comunicação das imagens

médicas chamada DICOM (*Digital Imaging and Communications in Medicine*), que será brevemente apresentado no tópico a seguir.

No contexto desta pesquisa, os objetos de interesse e os elementos de *background* das imagens serão diferenciados por *global thresholding*, cujos parâmetros serão baseados na escala de unidades Hounsfield, que é um método rápido e efetivo para atingir o resultado esperado (McMenamin et. al., 2014).

2.1.3 *Digital Imaging and Communications in Medicine*

Com o aumento do uso de sistemas digitais produzidos por diferentes fabricantes na medicina, especialmente a TC e a RM, a criação de padrões que facilitassem a troca de informações relevantes entre profissionais tornou-se necessária. A transmissão de dados padronizados, como diagnósticos e imagens, tem como objetivo melhorar a conectividade e a compatibilidade, e otimizar o fluxo de trabalho (Mildenberger, Eichelberg e Martin, 2001).

Através da cooperação entre a *American College of Radiology (ACR)* e a *National Electrical Manufacturers Association (NEMA)*, no ano de 1993, foi publicado o padrão DICOM (*Digital Imaging and Communications in Medicine*) 3.0, resultado do aperfeiçoamento de outros dois padrões publicados anteriormente, o ACR-NEMA 1.0, de 1985, e o ARC-NEMA versão 2.0, de 1988 (Mildenberger, Eichelberg e Martin, 2001).

O padrão DICOM fornece definições acerca de terminologia, decodificação e estrutura de dados com identificadores específicos para serviços e objetos, como imagens e dados de pacientes e relatórios, tornando-o independente de características individuais atribuídas por fabricantes (Mildenberger, Eichelberg e Martin, 2001).

Em exames de TC, por exemplo, o padrão DICOM garante o fornecimento de uma série de informações relevantes, presentes no chamado cabeçalho (*header*) das imagens, uma lista de atributos na qual estão os dados sobre a modalidade do exame (RM ou TC, por exemplo), descrição do exame, área examinada, duração do procedimento, características da aquisição – como espessura das fatias, resolução e tamanho da matriz, dados sobre o paciente (sexo e idade), pós-processamento, filtros aplicados, exposição à radiação (CT), dentre muitos outros (Mildenberger, Eichelberg e Martin, 2001).


Capítulo 3 - PROCESSAMENTO DE IMAGENS DIGITAIS

Imagens digitais são figuras convertidas para um formato binário legível por computador, e entende-se por imagem, normalmente, uma figura estática que não varia com o tempo (Bovik, 2009).

Segundo Gonzalez e Woods (2006), uma imagem pode ser definida como uma função 2d, $f(x, y)$, em que x e y são coordenadas espaciais, e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto. Imagens digitais são compostas por um número finito de elementos, cada um com posição e intensidade únicas, chamados de *pixels*.

Como dito anteriormente, há uma grande diversidade de aplicações que se beneficiam do processamento de imagens, como representado na Figura 5. A aplicação do processamento de imagens na medicina, por sua vez, data do final da década de 1960 e início da década de 1970 (Gonzalez e Woods, 2006).

Figura 5 – Exemplos de áreas beneficiadas pelo processamento de imagens digitais.




Fonte: adaptado de *The Essential Guide to Image Processing* (2009).

Os níveis de processamento de imagem podem ser divididos em três grupos de acordo com sua finalidade, sendo estes: processamento de baixo nível, que envolve operações primitivas como redução de ruído e aumento de contraste e nitidez, no qual imagens são o produto de entrada (*input*) e também de saída (*output*); processamento de nível médio, que envolve processos de segmentação, descrição e classificação de objetos, onde imagens correspondem ao *input*, e o *output* é composto por atributos extraídos destas imagens; e processamento de alto nível, no qual é realizada a análise e interpretação dos

atributos da imagem processada (Gonzalez e Woods, 2006). A Figura 6 e a Figura 7 apresentam exemplos de processamentos de nível baixo e médio, respectivamente.


Figura 6 – Processamento de nível baixo. À esquerda, a imagem original, no centro, a imagem após operação de aumento de nitidez e, à direita, a imagem após aplicação de um filtro de média de tamanho 9x9 pixels.



Fonte: adaptado de *Natural Knee Data* (2020).

A Figura 6 mostra uma única fatia de um exame de TC na qual foram aplicados um filtro de nitidez (*sharpening*), que destaca transições de intensidade na imagem e pode ser executado através de métodos como o Laplaciano, e um filtro de média, que borra a imagem através da substituição dos seus valores de intensidade pela média destes valores definida por uma máscara de m linhas e n colunas (Gonzalez e Woods, 2006). O funcionamento destas e de outras operações será abordado em detalhes no tópico **Transformações de Intensidade e Filtragem Espacial**.

Figura 7 – Processamento de nível médio. À esquerda, a imagem original, à direita, a imagem após aplicação de um processo de classificação.



Fonte: adaptado de *Natural Knee Data* (2020).

A Figura 7 mostra um exemplo de processamento de nível médio, no qual o objeto de entrada, à esquerda, é uma fatia de uma imagem de TC, e o objeto de saída, à direita, é um elemento extraído da imagem obtido através da classificação dos elementos da imagem original.

Ainda sobre a Figura 7, Analisando-se o resultado obtido, percebe-se que os ossos do indivíduo foram segmentados, enquanto o restante da imagem foi desprezado. A detecção e análise deste resultado representa um processamento de alto nível.


As ferramentas de processamento, por sua vez, podem ser classificadas em outros três tipos, que operam de forma distinta sobre os dados da imagem, sendo estes:

- *operações pontuais* - aplicadas sobre elementos da imagem individualmente, desconsiderando a posição do *pixel* e sua relação com a sua vizinhança, operando nos valores de intensidade da imagem;
- *operações aritméticas entre imagens de mesma dimensão espacial* - que também operam pontualmente sobre os *pixels*, mas levam em consideração dados de mais de uma imagem, sendo operações úteis para tratamento de ruído e detecção de mudanças ou direção;

- *operações geométricas* - baseadas na posição espacial dos elementos da imagem, que mudam as coordenadas das intensidades, sendo utilizadas para rotação, translação, distorção e outros (Bovik, 2009).

A Figura 8 mostra a imagem de entrada, um exemplo de operação pontual, operação aritmética e operação geométrica, respectivamente.

Figura 8 – (a) Imagem original. (b) Operação aritmética: gradiente de Sobel. (c) Operação pontual: negativo da imagem. (d) Operação geométrica: rotação da imagem.



Fonte: adaptado de *Natural Knee Data* (2020).

Na Figura 8 (a) encontra-se a imagem de entrada, que corresponde à uma fatia de uma imagem de TC. A Figura 8 (b) mostra o resultado da aplicação de um filtro de Sobel, utilizado para obtenção do gradiente da imagem (uma mudança da direção das intensidades da imagem). A Figura 8 (c) mostra uma operação de intensidade cujo *output* é o negativo da imagem de entrada. Por fim, a Figura 8 (d) mostra uma operação geométrica para rotação da imagem de entrada em 45 graus (Gonzalez e Woods, 2006).

3.1 Introdução à Amostragem e Quantização de Imagens

Os sinais obtidos através de um exame de TC precisam ser representados e processados em forma digital para que possam ser visualizados e analisados em um computador (Gomes e Velho, 2002). O processamento destes sinais é complexo e alguns termos serão definidos em seguida para auxiliar o leitor.

Segundo Gomes e Velho (2002), dado um sinal contínuo, definido por uma função f , este pode ser submetido a processos de:

- *discretização* – processo de conversão de um sinal contínuo em uma representação discreta;
- *amostragem* – processo de discretização do domínio da função f ;
- *quantização* – processo de discretização do contradomínio da função f .


O sinal amostrado e quantizado é chamado, então, de *senal digital*. Similarmente, uma imagem discreta (amostrada) e quantizada é chamada de *imagem digital* (Gomes e Velho, 2002).

Devido à complexidade da teoria de sinais, que envolve operações matemáticas sofisticadas (Gomes e Velho, 2002), as técnicas apresentadas a seguir serão brevemente discutidas. Se for do interesse do leitor, recomenda-se a leitura das referências utilizadas neste subtópico para um entendimento aprofundado do assunto, especialmente através do livro intitulado *Computação Gráfica: Imagem*, de Jonas Gomes e Luiz Velho (2002).

3.1.1 Amostragem (*Sampling*)

A Figura 9 mostra o processo de amostragem de um sinal contínuo unidimensional, no qual as amostras foram indexadas por variáveis discretas (Bovik, 2009).

Figura 9 – Amostragem de um sinal contínuo unidimensional.



Fonte: *The Essential Guide to Image Processing (2009)*.

No caso apresentado na Figura 9, o sinal amostrado pode ser visto como um vetor numérico. Assim, se o sinal é finito em extensão, o vetor pode ser armazenado e digitalmente processado como uma matriz de dados, e os *pixels*, mencionados anteriormente, correspondem a cada elemento indexado dessa matriz de dados (Bovik, 2009).

A amostragem de sinais deve ser feita de forma que informações visuais relevantes sejam preservadas, sem que haja perda significativa da resolução espacial ou adição de artefatos. Na obtenção de imagens digitais, a amostragem representa a digitalização dos valores das coordenadas (Bovik, 2009; Gonzalez e Woods, 2006).

3.1.2 Quantização (*Quantization*)

Os valores obtidos de uma imagem são, normalmente, intensidades, uma vez que imagens são o registro da intensidade do sinal incidente no sensor. Os valores dos *pixels*, quando representados por tons de cinza, são chamados de níveis de cinza (*gray levels*) (Bovik, 2009).

A quantização, também chamada de *discretização de cor* (Gomes e Velho, 2002), é o processo de conversão de valores contínuos da imagem, que possui uma escala contínua, para uma imagem de valores discretos, com uma escala discreta. Ou seja,

quando o nível de cinza do *pixel* de uma imagem é quantizado, ele passa a fazer parte de um conjunto finito de números (Bovik, 2009).

Por conveniência, os valores de intensidade costumam ser mapeados por uma transformação linear e passam a ser um conjunto finito de inteiros não negativos $\{0, \dots, K - 1\}$, onde K é tipicamente uma potência de 2: $K = 2^B$. Portanto, K representa o número de níveis de cinza possíveis, e o número de bits alocados para cada *pixel* na escala de cinza é B , onde B é um número natural. Se $B = 8$, por exemplo, a escala de intensidades possui 256 valores que variam entre 0 e 255 (Bovik, 2009).

Segundo Gonzalez e Woods (2006), uma imagem amostrada para a geração de uma matriz 2d, $f(x, y)$, contendo M linhas e N colunas, sendo (x, y) coordenadas discretas, pode ser representada em forma de equação da seguinte maneira:

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, N - 1) \\ f(1,0) & f(1,1) & \dots & f(1, N - 1) \\ \vdots & \vdots & \dots & \vdots \\ f(M - 1, 0) & f(M - 1, 1) & \dots & f(M - 1, N - 1) \end{bmatrix} \quad (3.1)$$

onde cada elemento desta matriz de dados é um *pixel*. A quantização, portanto, corresponde à digitalização dos valores da amplitude da imagem.

3.2 Transformações de Intensidade e Filtragem Espacial

Métodos de transformação de intensidade e filtragem espacial são realizados no chamado domínio espacial, que é o plano da própria imagem. As transformações de intensidade operam sobre cada *pixel* individualmente, enquanto a filtragem espacial leva em consideração a vizinhança dos *pixels* (Gonzalez e Woods, 2006).

Os processos que ocorrem no domínio espacial podem ser denotados a partir da seguinte expressão:

$$g(x, y) = T[f(x, y)] \quad (3.2)$$

onde $f(x, y)$ é a imagem de entrada, $g(x, y)$ é a imagem de saída, e T é um operador ou filtro. Se a operação realizada nos *pixels* da imagem for linear, o filtro é chamado de filtro espacial linear, se a operação for não linear, o filtro é chamado não linear (Gonzalez e Woods, 2006).

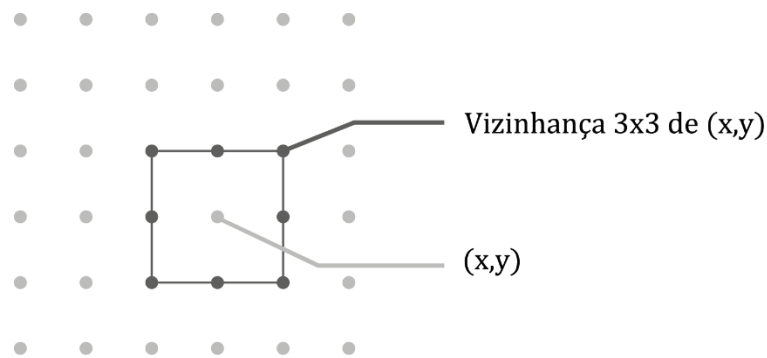
O termo “filtro”, também chamado de máscara ou *kernel*, vem do processamento no domínio da frequência, no qual a filtragem determina a aceitação (*passing*) ou rejeição de determinada frequência. Por exemplo, um filtro que aceita baixas frequências é chamado de filtro “passa-baixa” ou, do inglês, *lowpass filter*, que tende a suavizar a imagem (Gonzalez e Woods, 2006). Um resultado semelhante pode ser obtido através da aplicação de filtros espaciais, como mostra a imagem à direita na Figura 6, por exemplo (Gonzalez e Woods, 2006).

Esse tipo de processamento tem como objetivo o aprimoramento da imagem, manipulando-a para que esta se torne mais adequada para os fins pretendidos (Gonzalez e Woods, 2006). Além das transformações apresentadas na Figura 6 e na Figura 7, a filtragem espacial e as transformações de intensidades possuem outras aplicações, como manipulação de contraste, detecção de bordas, realce e muitas outras (Gonzalez e Woods, 2006).

3.2.1 Vizinhaça de *Pixels*

Algumas das operações apresentadas anteriormente e outras que serão discutidas a seguir ocorrem a partir da manipulação da vizinhaça de um determinado *pixel*. Normalmente, essa vizinhaça corresponde à uma área retangular, centrada em (x, y) , e em tamanho geralmente muito menor que a imagem (Gonzalez e Woods, 2006). A Figura 10 mostra um exemplo de vizinhaça de *pixel*.

Figura 10 – Vizinhança de um pixel no ponto (x,y) .



Fonte: o autor (2020).

A Figura 10 representa uma imagem de tamanho 6×6 *pixels* na qual uma vizinhança de tamanho 3×3 *pixels* foi destacada ao redor de um ponto arbitrário (x, y) .

Um *pixel* p , nas coordenadas (x, y) , possui quatro vizinhos verticais e horizontais, cujas coordenadas são dadas por

$$(x + 1, y), (x - 1, y), (x, y + 1), (x, y - 1)$$

e essa estrutura recebe o nome vizinhança-4 de p , denotada por $N_4(p)$. No caso da vizinhança diagonal de p , as coordenadas são dadas por

$$(x + 1, y + 1), (x + 1, y - 1), (x - 1, y + 1), (x - 1, y - 1)$$

sendo esse tipo de vizinhança denotada por $N_D(p)$. A soma das vizinhanças $N_4(p)$ e $N_D(p)$ forma a vizinhança-8, denotada por $N_8(p)$, demonstrada no exemplo da Figura 10. Se (x, y) estiver em alguma das bordas da imagem, um ou mais elementos da vizinhança de p podem estar fora daquela, o que pode ser solucionado através de um *padding*, ou seja, adicionando elementos com a intensidade desejada à borda da imagem (Sonka, Hlava e Boyle, 2014).

3.2.2 Filtragem Linear

O filtro é linear se a aplicação T for um operador linear, isto é


$$T(\lambda f) = \lambda T(f); \quad (3.3)$$

$$T(f + g) = T(f) + T(g) \quad (3.4)$$

onde λ é um número real e f e g são duas imagens. A primeira condição afirma que a resposta do filtro é invariante com relação ao escalamento constante das intensidades de cor da imagem, e a segunda condição afirma que a resposta do filtro no processamento de duas imagens que se combinam aditivamente se faz de forma independente em cada imagem (Gomes e Velho, 2002).

O processo de filtragem gera um novo *pixel* nas mesmas coordenadas do centro da vizinhança na qual um filtro foi aplicado. Vale ressaltar que o *pixel* gerado é armazenado em uma nova imagem e não substitui o *pixel* na imagem original, uma vez que isso alteraria a imagem enquanto ela está sendo processada, o que afetaria o resultado do processamento (Gonzalez e Woods, 2006). A Figura 11 demonstra o funcionamento desta operação.

Figura 11 – Aplicação de um *kernel* de tamanho 3x3 sobre uma vizinhança de mesmo tamanho em uma imagem.



Fonte: *Digital Image Processing* (2006).

A Figura 11 ilustra a mecânica da filtragem linear: segundo Gonzalez e Woods (2006), em qualquer ponto (x, y) da imagem, f , a resposta, $g(x, y)$, corresponde à soma dos produtos dos coeficientes do filtro, $w(x, y)$, e dos *pixels* da imagem com os quais o filtro interagiu:

$$g(x, y) = w(-1, -1)f(x - 1, y - 1) + w(-1, 0)f(x - 1, y) + \dots \\ + w(0, 0)f(x, y) + \dots + w(1, 1)f(x + 1, y + 1).$$

O coeficiente do centro do filtro, $w(0,0)$, alinha-se ao *pixel* da imagem no ponto (x, y) . Para uma máscara de tamanho $m \times n$, assume-se que $m = 2a + 1$ e $n = 2b + 1$, onde a e b são inteiros positivos. Ou seja, os filtros aqui discutidos possuem dimensões ímpares (Gonzalez e Woods, 2006). Ainda de acordo com Gonzalez e Woods (2006), a filtragem espacial linear de uma imagem de tamanho $M \times N$ com um filtro de tamanho $m \times n$ é, em geral, dada pela expressão

$$g(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t) \quad (3.5)$$

onde x e y variam até que cada *pixel* em w visite cada *pixel* em f .

O processo de mover um filtro sobre uma imagem e computar a soma dos produtos em cada local é chamado correlação, enquanto a aplicação de um filtro rotacionado em 180° é chamada convolução. Contudo, é comum dizer que um filtro, como o mostrado na Figura 11, é chamado de filtro de convolução, ou *kernel* de convolução, para denotar uma filtragem espacial, mesmo quando a operação realizada é de correlação (Gonzalez e Woods, 2006).

A partir dos conceitos apresentados, pode-se entender o funcionamento dos filtros apresentados anteriormente, citados e apresentados na Figura 6 e na Figura 7. A imagem à direita na Figura 6, por exemplo, mostra o resultado da aplicação de um filtro de média, que funciona através da substituição de cada *pixel* da imagem pela média dos níveis de intensidade na vizinhança definida pelo *kernel*, o que resulta em uma imagem com transições de intensidade menos abruptas (Gonzalez e Woods, 2006).

A Figura 12, a seguir, mostra dois filtros de suavização: um filtro de média padrão e um filtro de média ponderada.

Figura 12 – Dois filtros de média de tamanho 3 x 3.

$$\frac{1}{9} \times \begin{array}{|c|c|c|} \hline 1 & 1 & 1 \\ \hline 1 & 1 & 1 \\ \hline 1 & 1 & 1 \\ \hline \end{array} \quad \frac{1}{16} \times \begin{array}{|c|c|c|} \hline 1 & 2 & 1 \\ \hline 2 & 4 & 2 \\ \hline 1 & 2 & 1 \\ \hline \end{array}$$

Fonte: Digital Image Processing (2006).

Como dito anteriormente, o filtro mostrado à esquerda, na Figura 12, retorna o valor médio dos *pixels* da imagem sob a máscara. Os valores da máscara são todos iguais a 1 pois, computacionalmente, é mais vantajoso dividir o resultado da filtragem por 9 do que atribuir o valor 1/9 para cada coeficiente da máscara (Gonzalez e Woods, 2006). A imagem à direita é uma máscara que retorna a *média ponderada* dos valores da imagem, dando mais importância (*weight*) para alguns *pixels* em detrimento de outros, o que é feito com base na distância dos *pixels* para o centro da máscara. Como no caso anterior, o resultado da filtragem é dividido pela soma dos coeficientes do filtro, ou seja 16 (Gonzalez e Woods, 2006).


A fim de exemplificar matematicamente o funcionamento do que acaba de ser dito, com base na Equação (3.5), a filtragem de uma imagem de tamanho $M \times N$ por um filtro de média ponderada de tamanho $m \times n$ (no qual m e n são ímpares) é dada pela expressão

$$g(x, y) = \frac{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t)}{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t)} \quad (3.6)$$

na qual os parâmetros são os mesmos definidos para a Equação (3.5). A imagem filtrada é obtida pela aplicação da equação (3.6) para $x = 0, 1, 2, \dots, M - 1$ e $y = 0, 1, 2, \dots, N - 1$ (Gonzalez e Woods, 2006).

A Figura 13 mostra o resultado da aplicação de filtros de média de diferentes tamanhos, $m \times n$, sobre a mesma imagem.

Figura 13 – Imagem original de tamanho 500x500 pixels (canto superior esquerdo) e imagens suavizadas por filtro de média de tamanho $m = 3, 5, 9, 15$ e 35 , respectivamente.



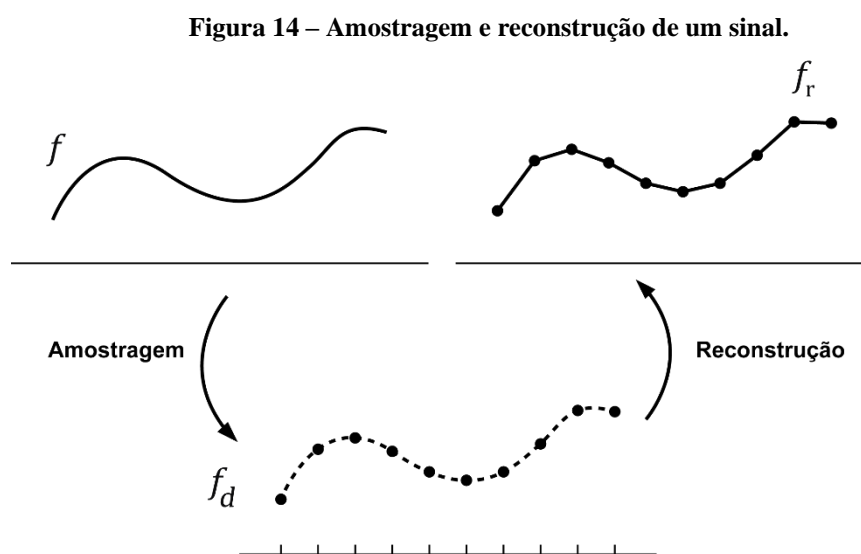
Fonte: *Digital Image Processing* (2006).

Nota-se, a partir da Figura 13, que quanto maiores as dimensões do filtro, mais evidente é o efeito da operação na imagem. Após a aplicação de um filtro de tamanho $m = 35$, alguns elementos foram eliminados e as bordas dos elementos da imagem praticamente não podem mais ser identificadas.

Como mencionado anteriormente, no processo de aquisição e formação das imagens tomográficas, filtros de convolução são aplicados para remover o *blurring* gerado no processo de retroprojeção, enquanto outros procedimentos acentuam componentes de alta frequência espacial, visando aumentar a nitidez das bordas da imagem (Haaga et al., 1996).

3.2.3 Reconstrução de Imagens

No tópico **Amostragem (Sampling)**, o processo de amostragem foi definido como a discretização de um sinal f com o intuito de digitalizar os valores das coordenadas de uma imagem digital. A *reconstrução* de uma imagem representa o processo inverso, no qual utiliza-se um processo de interpolação para obtenção do sinal original f , ou de uma aproximação f_r deste (Gomes e Velho, 2002). A Figura 14 exemplifica o processo de amostragem e reconstrução de um sinal.



Fonte: Computação Gráfica: Imagem (2002).

A Figura 14 mostra um sinal contínuo f , o resultado do processo de amostragem, f_d , e o resultado do processo de reconstrução, f_r , desse sinal por interpolação linear (Gomes e Velho, 2002).


Métodos de interpolação de imagem são utilizados em tarefas como ampliação, redução, rotação e correções geométricas. Estes métodos funcionam utilizando dados conhecidos para estimar valores em locais desconhecidos (Gonzalez e Woods, 2006).

Quando se altera a dimensão de uma imagem, por exemplo, seja para aumentá-la ou diminuí-la, altera-se também a distância entre os *pixels* desta imagem. A interpolação usa os valores de intensidade de locais conhecidos para estimar os valores de intensidade de locais desconhecidos, onde estão os *pixels* da imagem reamostrada (Gonzalez e Woods, 2006). Existem diferentes métodos de interpolação, como:

- *interpolação por vizinho mais próximo* – que atribui a intensidade do *pixel* mais próximo ao valor do novo *pixel*. Se houver dois ou mais *pixels* igualmente distantes do *pixel* criado, escolhe-se o mais adequado para o caso em questão de acordo com um critério (*pixel* à esquerda ou acima, por exemplo) que deve ser consistente. Este método simples gera a distorção de bordas retas, além de criar outros artefatos na imagem, e por isso possui aplicações específicas e limitadas;
- *interpolação bilinear* - que utiliza os quatro vizinhos mais próximos para estimar a intensidade do novo *pixel*. Os resultados da interpolação bilinear são significativamente melhores quando comparados aos da interpolação por vizinho mais próximo;
- *interpolação bicúbica* – que utiliza os dezesseis vizinhos mais próximos para estimar o valor de intensidade do *pixel* gerado. Este método gera resultados ainda melhores que os da interpolação bilinear, preservando uma quantidade maior de detalhes (Gonzalez e Woods, 2006).

A Figura 15 mostra exemplos das três técnicas citadas.

Figura 15 – (a) Imagem original, na qual um quadrado destaca a região mostrada nas imagens seguintes após interpolação (b) por vizinho mais próximo, (c) bilinear e (d) bicúbica, após aumento da imagem em 1200%.



Fonte: adaptado de *Natural Knee Data* (2020).

Percebe-se, na Figura 15, que a interpolação por vizinho mais próximo gerou distorções nas bordas dos elementos da imagem, enquanto as interpolações bilinear e bicúbica foram capazes de estimar melhor as intensidades dos *pixels* após o redimensionamento, fazendo com que as transições nas bordas sejam menos abruptas.

3.2.4 Filtragem Não Linear

Operadores não lineares são aqueles cuja ação depende dos valores encontrados na imagem. Nesse caso, a função T , na Equação (3.2), seria não linear. São técnicas não lineares, por exemplo: filtro mediano, operações pontuais de transformação logarítmica, equalização de histograma, manipulação de histograma (*histogram shaping*), e a filtragem por difusão anisotrópica (Bovik, 2009), que será abordada individualmente no tópico seguinte devido a sua importância para esta pesquisa.


O filtro de mediana, por exemplo, um dos mais comuns dentre os filtros não lineares, funciona de forma similar aos filtros de média. O valor de um *pixel* é substituído pela mediana dos valores de intensidade na vizinhança desse *pixel*:

$$\hat{f}(x, y) = \text{median}_{(s,t) \in S_{xy}} \{g(s, t)\} \quad (3.7)$$

o valor original do *pixel* em (x, y) é incluído no cálculo da mediana (Gonzalez e Woods, 2006).

Esse filtro é especialmente eficiente na remoção do tipo de ruído apelidado “*salt-and-pepper*” (sal e pimenta), que se assemelha à pontos pretos e brancos sobre a imagem (Gonzalez e Woods, 2006). A Figura 16 mostra esse caso.

Figura 16 – À esquerda: imagem original com ruído *salt-and-pepper*; no centro: imagem após aplicação de filtro de média de tamanho $m = 3$; à direita: imagem após aplicação de filtro de mediana de tamanho $m = 3$.



Fonte: *Digital Image Processing* (2006).


A partir da Figura 16 pode-se perceber claramente como o filtro de mediana é superior ao de média quando o objetivo é a remoção do ruído do tipo *salt-and-pepper*.

3.2.4.1 Filtro de Difusão Anisotrópica

O método de difusão anisotrópica foi proposto por Perona e Malik em 1990 (Perona e Malik, 1990). O objetivo do método é executar a suavização de uma imagem sem que sejam perdidas informações relevantes como as bordas de seus elementos. Ou seja, a suavização deve ser executada “dentro” de cada uma das regiões da imagem, e não entre estas regiões (como aconteceria durante a aplicação de um filtro de desfoque

Gaussiano ou de média). O resultado ideal, portanto, seria uma imagem cujo ruído tenha sido suprimido, porém, cujas bordas tenham sido preservadas (Perona e Malik, 1990). A Figura 17 exemplifica o funcionamento desta operação.

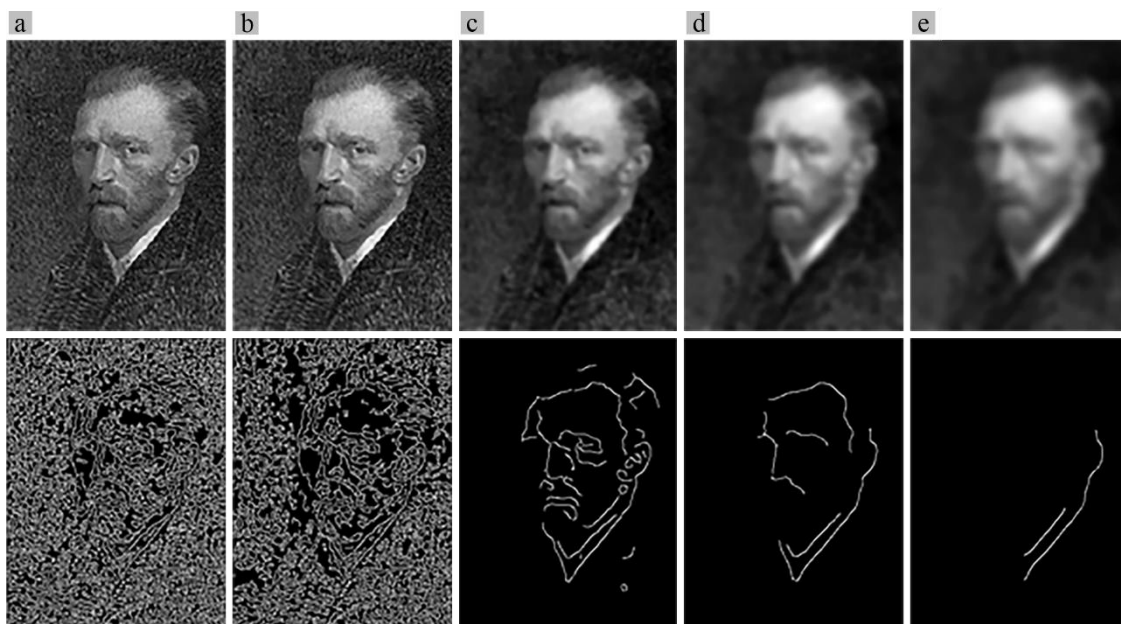
Figura 17 – Difusão Anisotrópica e bordas detectadas na imagem após a difusão. (a) Imagem original. Número de iterações: (b) 100, (c) 200, (d) 400, (e) 1000 iterações.



Fonte: adaptado de Vincent Van Gogh (1889).

A Figura 17 mostra a pintura intitulada “*Self Portrait*”, de Vincent Van Gogh (1889), após várias aplicações de difusão anisotrópica. Nota-se que o algoritmo gera a suavização das áreas da imagem, assim como os filtros de suavização já discutidos, porém, tenta preservar as bordas de seus elementos, mantendo a distinção entre estes mesmo após a aplicação de muitas iterações, o que pode ser visto nas imagens da fileira de baixo, que mostram as bordas detectadas em cada uma das imagens da fileira superior. A fim de comparação, a Figura 18 mostra a mesma imagem após aplicação de um filtro de desfoque Gaussiano.

Figura 18 – Desfoque Gaussiano e bordas detectadas na imagem após o desfoque. (a) Imagem original. Tamanho da máscara: (b) 3x3, (c) 15x15, (d) 25x25, (e) 35x35.




Fonte: adaptado de Vincent Van Gogh (1889).

A fileira superior da Figura 18 mostra os resultados do desfoque Gaussiano aplicado com máscaras de diferentes tamanhos à mesma imagem. A fileira de baixo mostra as bordas da imagem imediatamente acima, detectadas pelo algoritmo *Canny Edge Detector*, da biblioteca *scikit-image*, uma biblioteca de código aberto para a linguagem de programação Python (Walt et al., 2014). Nota-se que, em (a) e (b), muitos ruídos são detectados, impossibilitando a identificação dos elementos da imagem. A partir de (d), poucas bordas são detectadas na imagem, o que também prejudica a identificação dos elementos.

O método desenvolvido por Perona e Malik foi aperfeiçoado em 1998 por Black et al., que exploraram as relações entre a difusão anisotrópica e métodos estatísticos robustos (Black et al., 1998). Uma das melhorias propostas foi a utilização de uma nova função, baseada no estimador robusto *Tukey's biweight*, capaz de preservar melhor as bordas da imagem quando comparada com a função proposta por Perona e Malik, como demonstrado na Figura 19, além de melhorar o processo de interrupção automática da difusão da imagem (Black et al., 1998).

Figura 19 – Comparação entre o método de Perona e Malik, à esquerda, e a função de Tukey, à direita, após 500 iterações. As imagens na linha de baixo mostram as bordas identificadas nas imagens após o processamento.



Fonte: *Robust Anisotropic Diffusion* (1998).

Nota-se, pela Figura 19, que o método de Perona e Malik, após um número elevado de iterações, executa a difusão excessivamente, levando à perda de dados das bordas da imagem, enquanto o método baseado na função de Tukey é “interrompido” efetivamente, preservando informações das fronteiras dos elementos (Black et al., 1998).

No contexto desta pesquisa, o filtro de difusão anisotrópica foi fundamental para evidenciar a separação entre os ossos da tíbia e da fíbula de cada indivíduo, que são as duas estruturas mais próximas dentre as estudadas. Sem a aplicação prévia deste algoritmo, o processo de classificação dos elementos da imagem assumia que estes dois ossos correspondiam a uma única estrutura, o que prejudicava a execução dos procedimentos seguintes.

3.2.5 Processamento Morfológico de Imagens


A morfologia matemática é uma metodologia não linear, baseada na teoria dos conjuntos e em álgebra *booleana*, utilizada para extração de componentes da imagem que são úteis para a representação e descrição do formato de regiões, como fronteiras, esqueleto e casco convexo. É uma importante alternativa aos processamentos lineares, que não operam bem sobre aspectos geométricos da imagem (Dougherty e Lotufo, 2003; Gonzalez e Woods, 2006).

O foco do processamento morfológico é bastante amplo, e suas técnicas são utilizadas para aprimoramento, segmentação, restauração, detecção de bordas, análise de texturas, análise de partículas, desbaste (*thinning*), e para outros fins (Dougherty e Lotufo, 2003).

As operações morfológicas são baseadas na utilização de elementos estruturantes (SE – do inglês *structuring element*), que são pequenos conjuntos, normalmente de formato geométrico e tamanho menor que a imagem, sondando e quantificando a maneira como o SE se ajusta (o termo comumente utilizado é *fit*), ou não, à imagem original (Dougherty e Lotufo, 2003).

O procedimento é exemplificado na Figura 20, na qual uma imagem binária é sondada por um elemento estruturante quadrado, onde dois momentos são vistos, representados pelas posições do SE. No momento em que o SE está à esquerda, ele se encaixa na imagem, quando está à direita, não. Vale ressaltar que o SE não precisa, necessariamente, ser quadrado. Sua forma pode variar de acordo com a imagem ou característica desta sendo investigada (Dougherty e Lotufo, 2003).

Figura 20 – Imagem binária sendo sondada por um ES quadrado.



Fonte: *Hands-on Morphological Image Processing* (2003).

Como dito anteriormente, a linguagem utilizada na morfologia matemática é a teoria dos conjuntos, onde esses conjuntos representam objetos em uma imagem. Em imagens binárias, os conjuntos em questão são membros do espaço 2d de números inteiros Z^2 , em que cada elemento de um conjunto é um vetor 2d cujas coordenadas são (x, y) de um *pixel* branco ou preto de uma imagem (Gonzalez e Woods, 2006).


As operações básicas e fundamentais para processamento morfológico são chamadas de erosão (\ominus) e dilatação (\oplus), a partir das quais são geradas outras operações como a abertura (\circ) e o fechamento (\bullet) morfológico (Gonzalez e Woods, 2006).

Em imagens binárias, com A e B como conjuntos de Z^2 , a erosão de A por B é dada por:

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (3.8)$$

onde B é um elemento estruturante. Ou seja, a erosão de A por B é o conjunto de todos os pontos z , de forma que B transladado por z está contido em A (Gonzalez e Woods, 2006). A Figura 21 exemplifica o resultado da erosão morfológica.

Figura 21 – Erosão morfológica.



Fonte: *Digital Image Processing* (2006).

Na Figura 21, o elemento à esquerda é o conjunto A , o pequeno quadrado no centro da figura é o elemento estruturante B , e à direita pode-se ver o resultado da erosão de A por B , onde a linha tracejada representa os limites do conjunto original e não faz parte do resultado da erosão. Olhando para o resultado do processo, a área em cinza corresponde à área na qual o elemento estruturante é capaz de se deslocar de forma que esteja sempre contido em A (Gonzalez e Woods, 2006).


A dilatação ocorre de maneira similar. Com A e B como conjuntos de Z^2 , a dilatação de A por B é definida por:

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (3.9)$$

onde B é o elemento estruturante, e a dilatação de A por B é, então, o conjunto de todos os deslocamentos, z , de forma que \hat{B} e A se sobreponham pelo menos por um elemento (Gonzalez e Woods, 2006). A

Figura 22 exemplifica o processo de dilatação.

Figura 22 - Dilatação morfológica.



Fonte: *Digital Image Processing* (2006).

Na

Figura 22, à esquerda, está o conjunto A , no centro, o elemento estruturante B , e, à direita, é mostrado o resultado da dilatação de A por B , onde a linha tracejada indica o conjunto original, e a linha sólida representa o limite sobre o qual o elemento estruturante pode se mover de forma que ele ainda esteja em contato com o conjunto A (Gonzalez e Woods, 2006).

Nota-se que, diferentemente da erosão, que é uma operação de encolhimento (*shrinking*) ou afinamento (*thinning*), a dilatação “aumenta” ou “engrossa” objetos em imagens binárias, sendo esses resultados controlados pela forma do elemento estruturante utilizado (Gonzalez e Woods, 2006).

Como dito anteriormente, a partir da erosão e da dilatação são geradas as operações de abertura e fechamento morfológico. A abertura tende a suavizar o contorno de objetos, quebrar istmos estreitos e eliminar protusões finas. O fechamento também

tende a suavizar o contorno da imagem, mas geralmente funde as quebras em golfos finos, elimina pequenos buracos e preenche fendas em um contorno (Gonzalez e Woods, 2006).

A abertura do conjunto A pelo elemento estruturante B , denotada por $A \circ B$, é definida por


$$A \circ B = (A \ominus B) \oplus B \quad (3.10)$$

ou seja, a abertura de A por B corresponde à erosão de A por B , seguida pela dilatação do resultado pelo elemento estruturante B . O fechamento, por sua vez, denotado por $A \bullet B$, é dado por

$$A \bullet B = (A \oplus B) \ominus B \quad (3.11)$$

então, o fechamento de A por B corresponde à dilatação de A por B , seguida da erosão do resultado utilizando-se o mesmo elemento estruturante B (Gonzalez e Woods, 2006). A Figura 23 ilustra o funcionamento das operações de abertura e fechamento.

Figura 23 – Abertura e fechamento morfológico.



Fonte: *Digital Image Processing (2006)*.

Analisando-se a Figura 23, de (a) a (e) pode-se constatar o que foi dito anteriormente sobre a abertura morfológica:

- a erosão do conjunto A pelo SE B afinou o objeto e eliminou a ponte estreita que unia as duas áreas maiores, e alguns cantos da área externa do conjunto foram arredondados devido à forma do SE;
- a dilatação do resultado, ou seja, a abertura de A por B , arredondou outros cantos, tornou os objetos maiores e manteve a separação entre eles.

Similarmente, as imagens de (f) a (i) mostram o resultado do fechamento de A pelo mesmo elemento estruturante B :

- a dilatação do conjunto A pelo SE B engrossou o objeto e alargou a ponte que une as duas áreas maiores, e alguns cantos da área externa do conjunto foram arredondados devido à forma do SE;
- a erosão do resultado voltou a encolhê-lo e alterou novamente alguns cantos do objeto.

3.2.6 Segmentação de Imagens

A segmentação de imagens faz parte do grupo de processamento de nível médio mencionado anteriormente, no qual o *input* é uma imagem, e o *output* é uma característica dessa imagem, ou a característica a ser estudada. A segmentação é um processo que subdivide a imagem em suas regiões ou objetos constituintes (Gonzalez e Woods, 2006).


Algoritmos de segmentação para imagens monocromáticas geralmente são baseados em uma de duas categorias básicas quanto à forma de lidar com as propriedades dos valores de intensidade: descontinuidade e similaridade. Técnicas de descontinuidade, como *Edge-based segmentation*, baseiam-se na diferença entre as fronteiras de cada região e na diferença entre as fronteiras e o *background* da imagem. Técnicas de similaridade, como *Region-based segmentation*, baseiam-se na divisão da imagem em regiões semelhantes de acordo com determinado critério (Gonzalez e Woods, 2006).

Antes de abordar as técnicas de segmentação, o conceito de bordas (*edges*) em uma imagem digital será explicado. São *pixels* de borda (*edge pixels*) os *pixels* nos quais a intensidade de uma função de imagem muda abruptamente, e bordas são conjuntos de *pixels* de borda conectados (Gonzalez e Woods, 2006).

Existem diferentes modelos de borda, classificados de acordo com seus perfis de intensidade. A Figura 24 retrata estes modelos, que são: borda do tipo degrau (*step edge*), caracterizada pela transição entre dois níveis de intensidade que ocorrem, idealmente, à 1 *pixel* de distância; borda do tipo rampa (*ramp edge*), cujo perfil de intensidade é ocasionado pelo ruído ou *blurring* presente em imagens digitais; e borda do tipo telhado (*roof edge*), que representa uma linha em uma região, sendo a largura do telhado determinada pela espessura e nitidez da linha (Gonzalez e Woods, 2006).

Segundo Gonzalez e Woods (2006), é possível que os três modelos de bordas descritos estejam presentes em uma mesma imagem. Porém, devido às características de formação da imagem, os perfis de intensidade das bordas não costumam ser exatamente como os perfis ideais demonstrados na Figura 24, mas assemelham-se a eles.

Figura 24 – Representações ideais dos modelos de borda. Da esquerda para direita: *step edge*, *ramp edge* e *roof edge*.



Fonte: *Digital Image Processing* (2006).

Existem diversos métodos de segmentação, discutidos detalhadamente por Gonzalez e Woods (2006), que podem ser utilizados para diversos fins. Em seguida, alguns destes métodos serão brevemente abordados de acordo com suas principais finalidades. As técnicas a seguir são caracterizadas como *Edge-based segmentation*.

Para a detecção de pontos isolados, pode-se utilizar o operador Laplaciano, por exemplo, que é um operador linear e isotrópico (cuja resposta é independente da direção das descontinuidades da imagem na qual o filtro é aplicado). Através de um filtro, como o mostrado na Figura 25, o operador Laplaciano mede a diferença entre a intensidade de um *pixel* isolado e de seus 8-vizinhos. Como nos casos já discutidos, a soma dos coeficientes do filtro resulta em zero, indicando que a resposta do processamento será igual a zero em áreas de intensidade constante (Gonzalez e Woods, 2006).

Figura 25 – Filtro (Laplaciano) para detecção de pontos isolados.

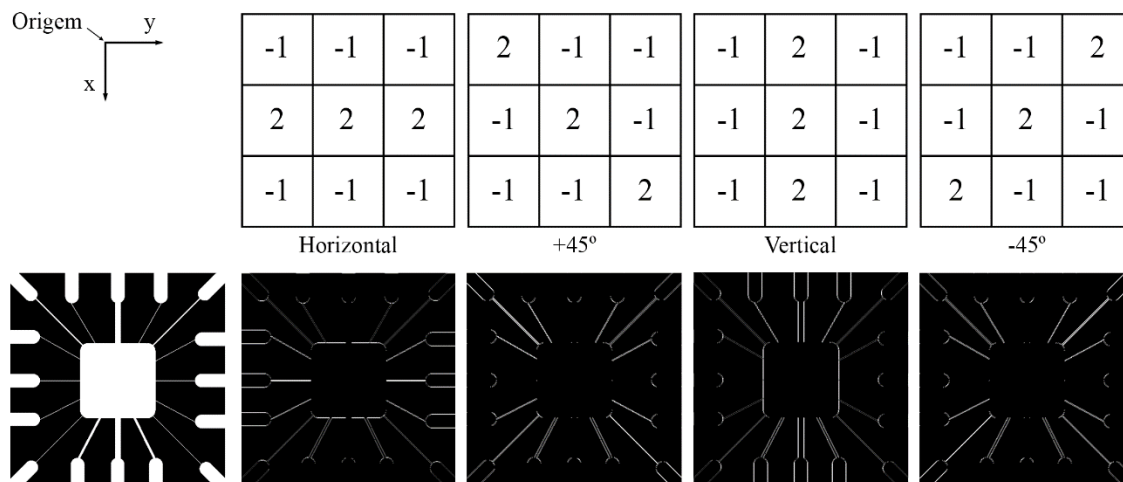
-1	-1	-1
-1	8	-1
-1	-1	-1

Fonte: *Digital Image Processing* (2006).

A máscara mostrada na Figura 25 também pode ser utilizada para identificação de linhas, mas os resultados obtidos podem gerar problemas como o aumento da espessura das linhas detectadas, o que é indesejado e precisa ser corrigido posteriormente. Outras máscaras que podem ser utilizadas na detecção de linhas são mostradas na Figura 26.

Diferentemente da máscara mostrada na Figura 25, as da Figura 26 não são isotrópicas, sendo aplicadas quando há interesse na detecção de linhas em direções específicas, e seus coeficientes de maior valor determinam a direção de preferência.

Figura 26 – Filtros para detecção de linhas. Na fileira de baixo são mostradas a imagem original (à esquerda) e os resultados gerados pelos filtros imediatamente acima das demais imagens.



Fonte: adaptado de *Digital Image Processing* (2006).

Como dito anteriormente, a detecção de bordas passa pela detecção de mudanças de intensidade em uma imagem. A ferramenta utilizada para encontrar a intensidade e a direção da borda no ponto (x, y) de uma imagem, f , é o gradiente, denotado por ∇f , e definido como o vetor

$$\nabla f \equiv \text{grad}(f) \equiv \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (3.12)$$

que tem a importante propriedade geométrica de apontar na direção da maior taxa de variação de f no ponto (x, y) . A magnitude (comprimento) do vetor ∇f , denotado por $M(x, y)$, onde

$$M(x, y) = \text{mag}(\nabla f) = \sqrt{g_x^2 + g_y^2} \quad (3.13)$$

é o valor da taxa de variação na direção do vetor gradiente. A direção do vetor gradiente é dado pelo ângulo

$$\alpha(x, y) = \tan^{-1} \left[\frac{g_y}{g_x} \right] \quad (3.14)$$

medido em relação ao eixo x (Gonzalez e Woods, 2006).

As máscaras mostradas na Figura 27, conhecidas como filtros ou operadores de Sobel, podem ser utilizadas na obtenção dos componentes do gradiente g_x e g_y em cada posição de *pixel* na imagem (Gonzalez e Woods, 2006).

Figura 27 – Operadores de Sobel, utilizados para detecção de bordas horizontais, verticais e diagonais, respectivamente.

-1	-2	-1	-1	0	1	0	1	2	-2	-1	0
0	0	0	-2	0	2	-1	0	1	-1	0	1
1	2	1	-1	0	1	2	-1	0	0	1	2

Fonte: *Digital Image Processing* (2006).

A Figura 27 mostra os filtros de Sobel. As duas máscaras à esquerda são utilizadas para implementar as equações

$$g_x = \frac{\partial f}{\partial x} = (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3) \quad (3.15)$$

e

$$g_y = \frac{\partial f}{\partial y} = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7) \quad (3.16)$$

onde os z correspondem a valores de intensidade em posições específicas, como mostra a Figura 28 (Gonzalez e Woods, 2006).


Figura 28 – Posições de z.

z_1	z_2	z_3
z_4	z_5	z_6
z_7	z_8	z_9

Fonte: *Digital Image Processing* (2006).

Os resultados obtidos pela aplicação dos diferentes operadores de Sobel são apresentados na Figura 29.

Figura 29 – Operadores de Sobel. Imagem original e os resultados, cada um obtido através da máscara ao seu lado.



Fonte: adaptado de *Digital Image Processing* (2006).

Como pode-se notar, as duas primeiras imagens processadas e apresentadas na Figura 29 mostram que as bordas horizontais e verticais foram detectadas pelos filtros,

enquanto as duas imagens da fileira de baixo mostram as bordas diagonais detectadas pelos outros dois filtros.

Além dos métodos mencionados, que se baseiam em filtrar uma imagem com uma ou mais máscaras, existem outros mais sofisticados, que levam em consideração outras informações da imagem, como ruído e a natureza das próprias bordas da imagem. Dentre estes métodos mais avançados, pode-se citar o método de Marr-Hildreth e o de Canny, por exemplo (Gonzalez e Woods, 2006).

Quanto às abordagens de *Region-based segmentation*, pode-se citar o método chamado *Thresholding*, ou limiarização: um método de implementação relativamente simples que divide uma imagem com base nas intensidades de suas regiões e/ou em suas propriedades (Gonzalez e Woods, 2006). Segundo a pesquisa de Van Eijnatten et al. (2018), a maioria das pesquisas relacionadas à segmentação de ossos a partir de imagens de TC é baseada no processo de *Image Thresholding*.

Supondo que uma imagem $f(x, y)$ possa ser dividida entre as regiões de interesse e seu *background*, a imagem passa a conter dois grupos que podem ser separados de acordo com a seleção de um limiar T . Então, qualquer ponto (x, y) na imagem em que $f(x, y) > T$ é chamado de *object point*, caso contrário, é chamado de *background point*. A imagem segmentada, $g(x, y)$, é dada por

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T. \end{cases} \quad (3.17)$$


Quando T é uma constante aplicável sobre a imagem como um todo, o processo dado por essa equação é chamado de *global thresholding* (Gonzalez e Woods, 2006).

Existem métodos mais complexos para detecção de elementos na imagem, como o *active contour*, também conhecido como *snakes* (Bovik, 2009). O método desenvolvido por (Chan e Vese, 2001), chamado *Active Contour Without Edges (ACWE)*, é capaz de detectar objetos cujas bordas não são necessariamente definidas por um gradiente de intensidade.

O método funciona através da evolução de uma curva, sujeita às restrições de uma determinada imagem, a fim de detectar objetos nessa imagem. Inicialmente, uma curva ao redor do objeto a ser detectado se move em direção ao seu interior (*interior normal*) e deve parar em sua borda (Chan e Vese, 2001).

Em pesquisa publicada no ano de 2013, o método de Chan e Vese foi adaptado para ser executado a partir de operadores morfológicos por (Marquez-Neila, Baumela e Alvarez, 2013). Embora os resultados obtidos sejam semelhantes, o método com base em morfologia é mais estável, rápido e fácil de aplicar (Marquez-Neila, Baumela e Alvarez, 2013). A Figura 30 ilustra o funcionamento desta técnica.

Figura 30 – Segmentação por contorno ativo com operadores morfológicos. São mostradas imagens após: 25, 50, 75, 100, 125, 150, 175 e 200 iterações, respectivamente.



Fonte: adaptado de *Natural Knee Data* (2020).

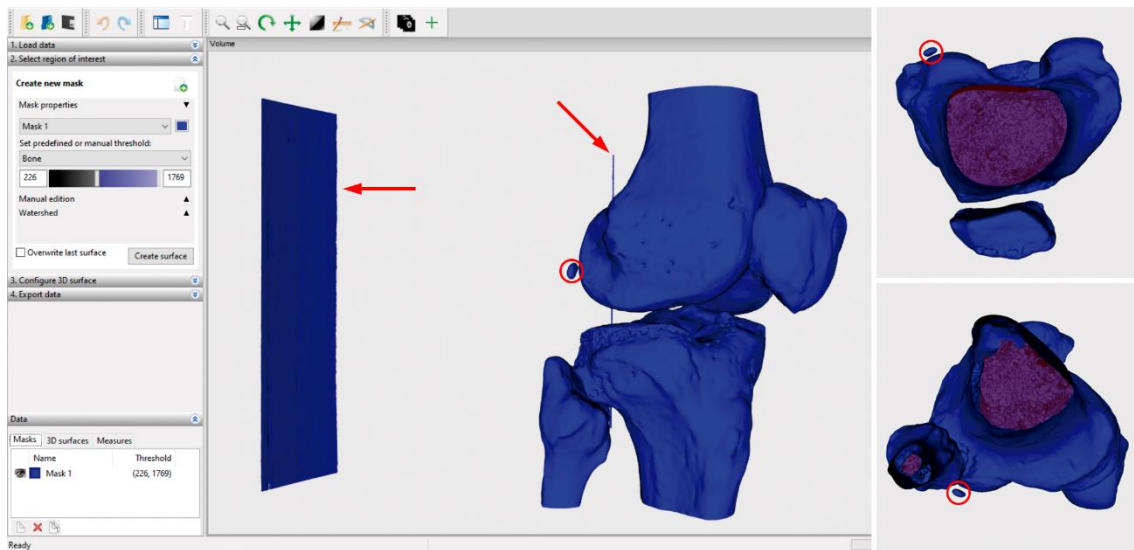
A Figura 30 mostra a progressão do algoritmo de segmentação proposto por (Marquez-Neila, Baumela e Alvarez, 2013). A imagem original corresponde a uma fatia de imagem de TC. O objeto segmentado ao final do processamento, mostrado na imagem do canto inferior direito, é parte de um fêmur.

No contexto desta pesquisa, o algoritmo de Marquez-Neila, Baumela e Alvares (2013) foi responsável por detectar e segmentar as superfícies dos ossos, desprezando todo e qualquer ruído no interior ou exterior destes objetos, representando o processo final de segmentação do método proposto.

Utilizada como exemplo em grande parte das figuras até aqui, a tomografia computadorizada tem sido a modalidade escolhida para segmentação do esqueleto humano devido ao contraste radiológico entre tecidos duros e moles gerado por ela (Pinheiro e Alves, 2015).

Embora existam *softwares*, como o InVesalius (Amorim et al., 2011), capazes de realizar a segmentação semiautomática de estruturas anatômicas, estes nem sempre oferecem muitos recursos de ajuste e refinamento do modelo gerado, que pode possuir ruídos e artefatos indesejados, como mostra a Figura 31. Estes objetos estranhos podem atrapalhar a visualização, a manipulação e a aplicação destes recursos.

Figura 31 – Segmentação realizada no software InVesalius 3.1. Os artefatos estão destacados por elementos vermelhos.



Fonte: adaptado de *Natural Knee Data* (2020).

O modelo da Figura 31 foi gerado através de um *thresholding* predefinido pelo *software* para a segmentação de ossos a partir de imagens de TC. O intervalo selecionado automaticamente para a segmentação dos ossos foi de 226 a 1769 UH (intensidade máxima da imagem segmentada). Contudo, o resultado obtido apresenta não somente os ossos (com falhas em sua superfície), mas também outros artefatos, neste caso, indesejados, como a mesa utilizada durante o exame e parte da estrutura interna dos ossos, que se assemelha a ruído na imagem.

3.2.7 *Marching Cubes*

Após o processo de segmentação das imagens, ou das diversas fatias de uma TC, é possível gerar malhas 3d, que auxiliam o entendimento de estruturas anatômicas complexas presentes nas fatias analisadas (Lorensen e Cline, 1987).

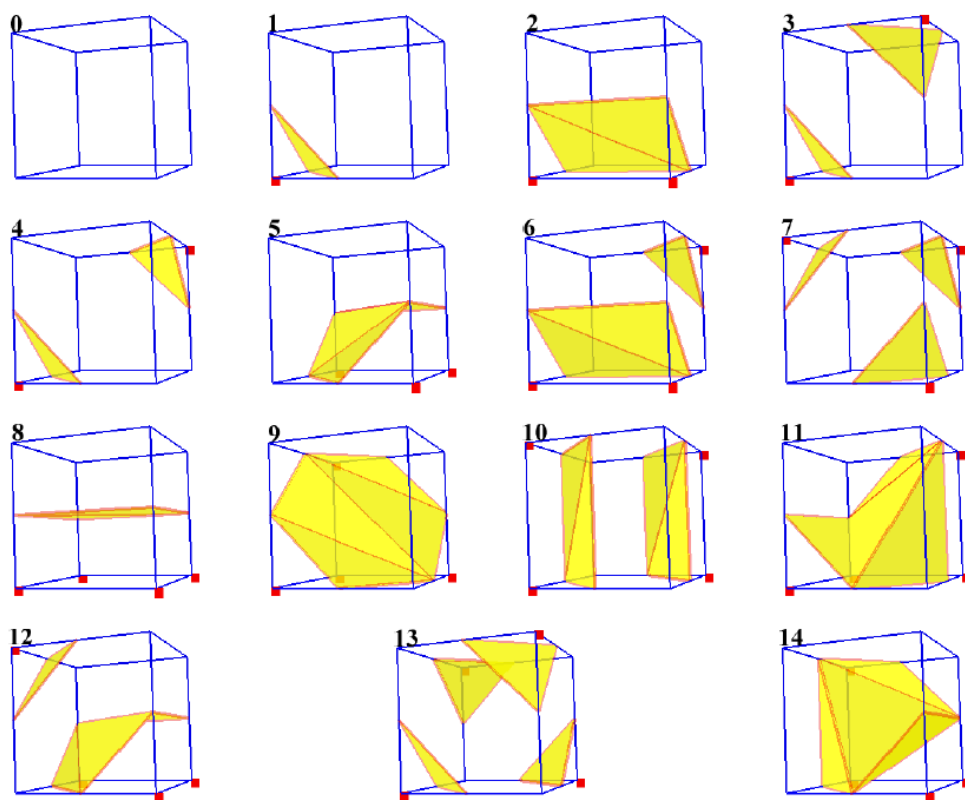
O algoritmo *Marching Cubes*, publicado em 1987 por W. E. Lorensen e H. E. Cline, é capaz de construir superfícies 3d de alta resolução. Este algoritmo cria uma representação poligonal de superfícies de densidade constante a partir de uma matriz 3d de dados (Lorensen e Cline, 1987).

A abordagem, baseada em “dividir e conquistar”, encontra as conectividades do modelo entre as fatias da imagem 3d. A partir de um cubo lógico, formado por oito *pixels*, quatro de cada duas fatias adjacentes da imagem, o algoritmo é capaz de localizar superfícies dentro do cubo em questão. Quando a superfície é localizada dentro do cubo, os próximos oito *pixels* são analisados. Assim, os cubos “marcham” pela imagem até que todas as superfícies sejam encontradas (Lorensen e Cline, 1987).

Com base em regras preestabelecidas, o algoritmo determina que uma superfície pode cruzar o cubo de maneiras limitadas. Isso permite que uma tabela (*lookup table*), contendo todas essas possibilidades, seja utilizada para acelerar a formação da superfície dentro dos cubos. A Figura 32 mostra a tabela utilizada no algoritmo original (Lorensen e Cline, 1987).

A Figura 32 mostra os 14 padrões, formados por uma ou mais superfícies triangulares, que podem compor cada cubo. Os vértices em vermelho representam os dados coletados na imagem original que foram caracterizados como pontos “dentro” da superfície, enquanto os demais vértices foram classificados como pontos “fora” da superfície (Lorensen e Cline, 1987).


Figura 32 – *Lookup table* original do algoritmo Marching Cubes.



Fonte: *Efficient implementation of Marching Cubes' cases with topological guarantees* (2012).

De acordo com Lewiner et al. (2012), o método de Lorensen e Cline (1987) foi aperfeiçoado ao longo dos anos, mas a maioria das técnicas modernas ainda são baseadas em *lookup tables* simples, o que não garante a consistência topológica do resultado. Assim, em 2012, Lewiner et al. propuseram a implementação de uma técnica para garantir um resultado topologicamente correto (Lewiner et al., 2012). A Figura 33 compara os resultados obtidos entre os métodos clássico e o de Lewiner et al. (2012).

Figura 33 – Superfícies geradas pelo algoritmo clássico do Marching Cubes e pelo método de Lewiner et al.



Fonte: *Efficient implementation of Marching Cubes' cases with topological guarantees (2012).*

O resultado obtido pelo algoritmo de Lewiner et al. (2012), mostrado à direita na Figura 33, performou melhor na geração da topologia das formas mostradas (*linked tori*) quando comparado ao algoritmo original.

Capítulo 4 - PYTHON

Python é uma linguagem de programação de alto nível, capaz de executar tarefas como computação numérica, desenvolvimento para *web*, programação de banco de dados, programação de rede, processamento paralelo, dentre outros (Chityala e Pudipeddi, 2014).

A linguagem é gratuita, está disponível para diversos sistemas operacionais – como Linux, Mac e Windows –, é uma linguagem interpretada e sintaticamente mais simples que outras linguagens, possui boa legibilidade, fácil depuração (*debug*) e grande variedade de módulos que podem ser utilizados para diversos fins. Além disso, programas escritos em Python podem ser importados para outras plataformas ou sistemas operacionais sem grandes alterações, além de haver uma ativa comunidade de desenvolvedores e usuários que mantém a linguagem atualizada (Chityala e Pudipeddi, 2014).

Uma ferramenta de grande relevância é a extensão NumPy, lançada em 2006, que provê funções universais que operam rapidamente sobre elementos individuais de matrizes (*arrays*) multidimensionais, além de fornecer funções adicionais para manipulação dessas matrizes. NumPy e outras extensões constituem a coleção de ferramentas chamada SciPy, que garante recursos avançados para computação científica em Python, possuindo grande relevância para o processamento de imagens (Oliphant, 2007).

A função *zoom*, por exemplo, disponibilizada pela biblioteca SciPy, foi utilizada para a reamostragem dos dados. A função promove a criação de novos *voxels* a partir da aplicação de um fator de escala, que nos casos estudados fez com que o número de fatias das imagens aumentasse, sendo as novas intensidades dos *voxels* estipuladas por interpolação cúbica.

Outro recurso importante é o módulo scikit-image, publicado em 2009, que fornece uma coleção de algoritmos para processamento de imagens, através de submódulos que executam tarefas como filtragem espacial, limiarização (*thresholding*), geração de histograma, operações morfológicas, segmentação e muitas outras (Walt et al., 2014).

Por ser tão versátil, foram criados pacotes nos quais a linguagem é adaptada para fins específicos, chamados de distribuições Python, que muitas vezes também fornecem editores, módulos de visualização e o Jupyter Notebook (Perez e Granger, 2015), um

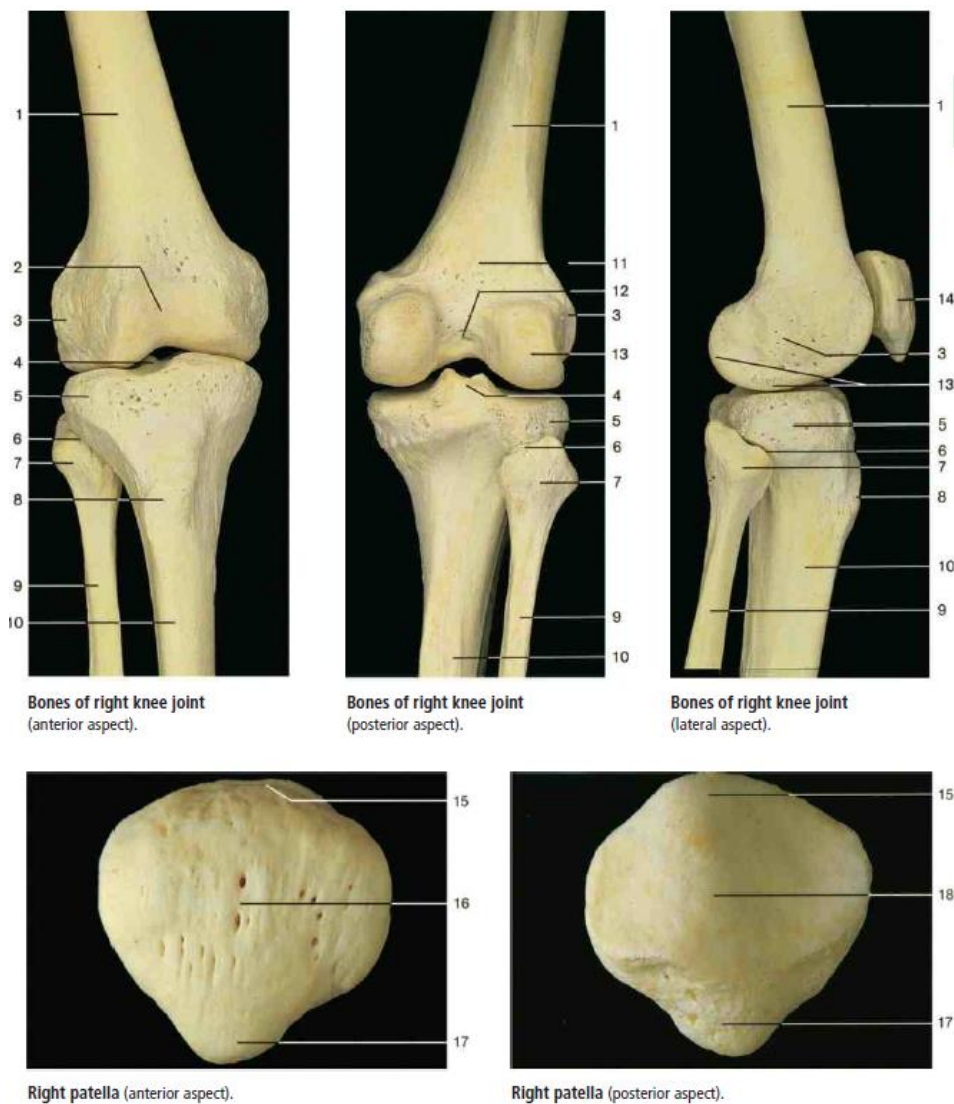
ambiente computacional *web* que permite criação e compartilhamento de códigos em um navegador (Bassi, 2017).

A distribuição Anaconda é uma distribuição Python (ou R) largamente utilizada para ciência de dados que possui muitos pacotes para preparação, análise e visualização de dados. Outros exemplos de distribuições Python são: Enthought Canopy e WinPython (Bassi, 2017).

Capítulo 5 - OSSOS DA ARTICULAÇÃO DO JOELHO

Os ossos que compõem a articulação do joelho são: extremidade distal do fêmur, extremidade proximal da tíbia, extremidade proximal da fíbula e a patela (Rohen et al., 1998). A Figura 34 apresenta fotografias dos ossos mencionados.

Figura 34 – Ossos da articulação do joelho.



Fonte: Color atlas of anatomy. A photographic study of the human body (1998).

As identificações numéricas presentes na Figura 34 estão associadas aos seus respectivos significados na Tabela 1.

Tabela 1 – Estruturas do joelho, com base na Figura 24.

1. Fêmur	10. Eixo da tíbia
2. Superfície patelar do fêmur	11. Superfície poplítea do fêmur
3. Epicôndilo lateral do fêmur	12. Fossa intercondilar do fêmur
4. Eminência intercondilar da tíbia	13. Côndilo lateral do fêmur
5. Côndilo lateral da tíbia	14. Patela
6. Posição da articulação tíbio-fibular	15. Base da patela
7. Cabeça da fíbula	16. Superfície anterior da patela
8. Tuberosidade da tíbia	17. Ápice da patela
9. Fíbula	18. Superfície articular da patela

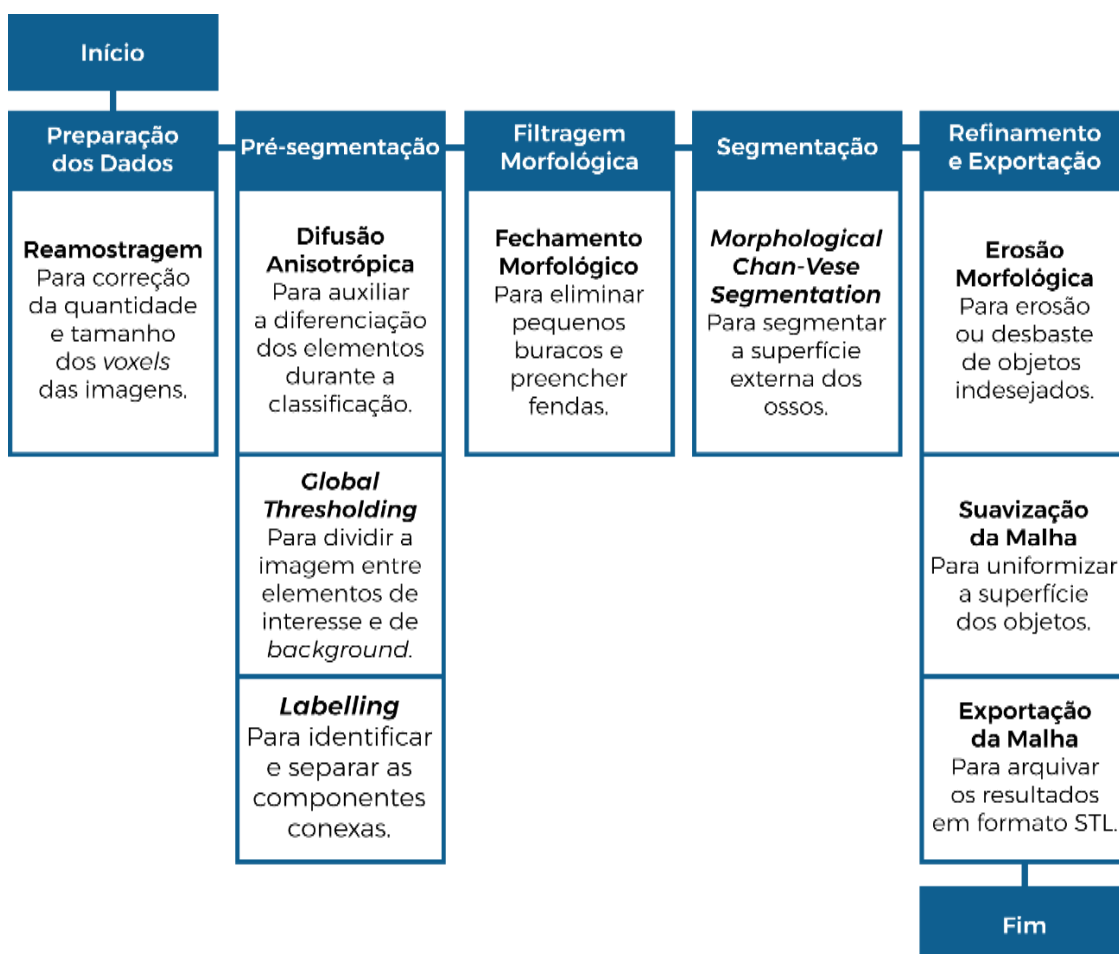
Fonte: *Color atlas of anatomy. A photographic study of the human body (1998).*

Embora a Tabela 1 detalhe as diferentes regiões dos ossos da articulação do joelho, o foco desta pesquisa será a segmentação das superfícies de todas as porções dos ossos mostradas na Figura 34. Os quatro ossos mostrados representam as regiões que se pretende obter dos quatro estudos de caso. Espera-se, ao final da pesquisa, que os quatro conjuntos de ossos segmentados tenham geometria e aspecto semelhante aos mostrados nas imagens.

Capítulo 6 - DESENVOLVIMENTO

Para atingir o objetivo proposto, uma sequência de processamento foi criada com base nas técnicas apresentadas nos tópicos de fundamentação teórica. Essa sequência é apresentada na Figura 35. O método desenvolvido foi aplicado a 4 diferentes conjuntos de imagens, sofrendo alterações em parâmetros específicos quando estritamente necessário.

Figura 35 – Sequência de processamento proposta.



Fonte: o autor (2020).

A modalidade de diagnóstico por imagem escolhida para o desenvolvimento deste projeto foi a Tomografia Computadorizada, devido às características já citadas, como a resolução das imagens e a diferenciação entre tecidos e estruturas anatômicas.

Os ossos da articulação do joelho foram escolhidos como objeto de estudo por diferentes motivos:

- como discutido no tópico introdutório, problemas relacionados à articulação do joelho correspondem à principal causa de incapacidade física crônica (INTO, 2020);
- a complexidade de segmentar diferentes estruturas próximas demanda estudo aprofundado e aplicação cuidadosa de técnicas de segmentação visando a confiabilidade dos resultados obtidos.

6.1 Materiais e Métodos

As imagens médicas foram obtidas no banco de dados *online* do Centro de Biomecânica Ortopédica da Universidade de Denver, Colorado, Estados Unidos (*Natural Knee Data*, 2020). A descrição dos espécimes utilizados nesta pesquisa encontra-se na Tabela 2, e as características de aquisição das imagens estão descritas na Tabela 3. O *scanner* utilizado foi o modelo da *Siemens SOMATOM Sensation 64 CT* (Harris et al., 2016 e Ali et al., 2016).

Tabela 2 – Descrição dos indivíduos examinados.

<i>Data</i>	Idade	Sexo	Peso	Altura	IMC
Indivíduo 01	50	Masculino	127.01 kg	175 cm	41.35
Indivíduo 02	44	Masculino	70.31 kg	183 cm	21.02
Indivíduo 03	72	Masculino	77.11 kg	183 cm	23.06
Indivíduo 04	61	Masculino	106.6 kg	183 cm	32.00

Fonte: *Natural Knee Data* (2020).

Tabela 3 – Características de aquisição das imagens de TC.

Data	Slices	Thickness (mm)	In-plane pixel spacing (mm)	In-plane resolution (mm)	Tube Current	Peak KV
I-01	251	0.6	0.390625 x 0.390625	512x512	186 mA	120
I-02	251	0.6	0.390625 x 0.390625	512x512	128 mA	120
I-03	310	0.75	0.390625 x 0.390625	512x512	125 mA	120
I-04	356	0.6	0.400390 x 0.400390	512x512	127 mA	120

Fonte: *Natural Knee Data (2020)*.

A importação das imagens de TC para o ambiente no qual foram processadas ocorreu através da biblioteca Pydicom (Mason, 2011). Os valores de intensidade das imagens importadas através desta biblioteca não são diretamente convertidos para UH, o que deve ser feito manualmente através da equação:

$$UH = IV * RescaleSlope + RescaleIntercept \quad (6.1)$$

onde *IV* corresponde aos valores de intensidade da imagem original, e *RescaleSlope* e *RescaleIntercept* são valores utilizados no cálculo das intensidade na formação das imagens de TC, e estão disponíveis no *header* da imagem (Xie et al., 2018).

Após a conversão das intensidades para UH, os valores preestabelecidos para diferentes substâncias do corpo, discutidos no tópico **Unidades Hounsfield**, passam a ser aplicáveis, embora em alguns dos casos mostrados a seguir a seleção de substâncias com base nas unidades Hounsfield não tenha gerado o resultado esperado, o que será discutido ao longo dos próximos tópicos. A fim de facilitar a navegação no texto, a Tabela 4 mostrará os valores em UH atribuídos às substâncias já mencionadas.

Tabela 4 – UH atribuídas para diferentes substâncias.

Substância	Unidades Hounsfield
Ar	- 1000
Gordura	Entre -300 e -100
Água	0
Músculo	Entre 10 e 70
Osso	+ 200
Osso denso	+ 1000

Fonte: *Medical Imaging Physics (2002)* e *Insight into images - principles and practice for segmentation, registration, and image analysis (2004)*.

Embora o método proposto tenha sido aplicado às imagens dos quatro indivíduos estudados, particularidades destas imagens exigiram alterações pontuais de determinados parâmetros. Para que essas alterações sejam demonstradas e analisadas, o processamento das imagens de cada indivíduo é abordado individualmente nos tópicos a seguir. No caso de processos com maior custo computacional, o tempo de processamento para cada indivíduo foi informado.


Todo o processamento das imagens foi realizado em Python 3.x, através do Jupyter Notebook e a distribuição Anaconda. Sistema utilizado para o processamento: Intel Core i7 com 32Gb de memória RAM e 8 núcleos.

6.2 Estudo de Caso: Indivíduo 01

6.2.1 Preparação dos Dados

As fatias (eixo Z) do exame do Indivíduo 01 foram geradas com 0.6 mm de espessura, enquanto a distância entre os *pixels* vizinhos nos eixos X e Y é de aproximadamente 0.39 mm. Isso quer dizer que a distância entre o centro dos *voxels* nos eixos X e Y da imagem é de 0.39 mm, e no eixo Z a distância é de 0.6 mm. A Figura 36 representa esse caso. Se a malha 3d for gerada com base nestes valores, sua aparência será distorcida. Portanto, os *voxels* devem ser reamostrados.

Figura 36 – Distância entre pixels da imagem do Indivíduo 01.




Fonte: o autor (2020).

A reamostragem dos *voxels* foi feita através da função *zoom* da biblioteca SciPy. O fator de reamostragem é dado pela divisão entre a espessura (*Z*) e a largura (*X*) dos *voxels*, e os valores de intensidade da imagem ampliada são estimados pelo algoritmo através de interpolação cúbica. O resultado obtido é uma imagem digital cujos *voxels* possuem as mesmas dimensões nos eixos *X*, *Y* e *Z*, sendo, portanto, cubos.

A Figura 37 exemplifica a diferença entre as malhas geradas antes e depois do processo de reamostragem. A imagem de saída possui mais camadas: 386 (135 a mais que a imagem original), enquanto as dimensões da imagem nos eixos *X* e *Y* permaneceram as mesmas ($512 \times 512 \text{ pixels}$). O tempo de processamento para esta operação foi de 31.74 segundos.

Figura 37 – Imagem original (esquerda) e imagem reamostrada (direita).



Fonte: o autor (2020).

À esquerda, na Figura 37, a malha gerada antes do processo de reamostragem mostra os ossos com aspecto achatado. O exemplo à direita representa melhor o aspecto real dos ossos.

6.2.2 Pré-Segmentação da Imagem


O objetivo da pré-segmentação é particionar a imagem entre as regiões de interesse (ROI – do inglês *Regions of Interest*) e o restante dos objetos da imagem. Ou seja, espera-se obter quatro conjuntos de imagens cujas fatias preservem a escala de valores de intensidade dos ossos, enquanto as demais estruturas passem a ter intensidade igual a 0 (preto). A sequência de processos testada e definida para a obtenção dos resultados esperados desta etapa é:

- filtragem por difusão anisotrópica,
- segmentação por *Global Thresholding*,
- *labelling*.

Para filtrar os ruídos e facilitar a distinção entre os objetos da imagem, o filtro de difusão anisotrópica baseado na função *Tukey's biweight* foi aplicado. Como explicado no tópico **Filtro de Difusão Anisotrópica**, esse filtro uniformiza as intensidades “dentro” das diferentes regiões da imagem enquanto preserva suas bordas. Após a aplicação do filtro, é importante que a distinção entre as estruturas seja evidente e que as bordas dos ossos sejam evidentes.

O filtro de difusão anisotrópica foi aplicado através do algoritmo disponível na biblioteca MedPy (Maier, 2020). O *input* corresponde à imagem reamostrada, e os parâmetros selecionados manualmente foram: o número de iterações e a opção da função na qual o algoritmo se basearia, sendo a opção 3 designada para executar o algoritmo a partir da função de *Tukey*. A Figura 38 mostra uma fatia da imagem de entrada e os resultados obtidos após a execução do algoritmo com 50, 250, 500 e 750 iterações.

Figura 38 – Imagem de entrada e após 50, 250, 500 e 750 iterações de difusão anisotrópica, respectivamente.



Fonte: o autor (2020).

Analisando-se a Figura 38, percebe-se que a partir de 250 iterações praticamente não se pode mais distinguir visualmente entre os tecidos musculares na região do joelho do Indivíduo 01, que foram uniformizados por não possuírem bordas bem definidas entre eles. Os ossos, representados em cinza claro, entretanto, tiveram suas bordas preservadas e seu interior uniformizado.

Embora a difusão anisotrópica altere os valores de intensidade da imagem, as intensidades das bordas dos objetos são pouco alteradas, o que é um fator relevante para as etapas futuras do processamento.

Vale ressaltar a importância da aplicação adequada do filtro de difusão anisotrópica para o sucesso da etapa seguinte. A tíbia e a fíbula são estruturas próximas e precisarão ser identificadas como dois objetos diferentes para que sejam processadas individualmente nas próximas etapas. Ou seja, a difusão anisotrópica ou qualquer outro processo não deve unir as bordas destes dois ossos especialmente próximos.

No caso do Indivíduo 01, a imagem após 50 iterações cumpre este requisito, porém, as etapas seguintes provaram que a escolha da imagem após 250 iterações facilitaria a separação e a classificação dos objetos da imagem e, portanto, foi selecionada como *input* para o processamento seguinte.

O tempo de processamento necessário para gerar cada uma das imagens da Figura 38 é demonstrado na Tabela 5.

Tabela 5 – Duração do processo de difusão anisotrópica das imagens do Indivíduo 01.

Número de iterações	50	250	500	750
Duração do processamento (s)	152.7510	764.6680	1525.8769	2288.5854

Fonte: o autor (2020).

O processo de segmentação por *global thresholding* foi aplicado para tornar a imagem binária. Com base na Equação 3.17 (**Segmentação de Imagens**), as intensidades de valor maior que T passam a ter valor 1, enquanto os valores menores ou iguais a T passam a ter valor 0.

A Tabela 4 mostra que, em imagens de TC, segundo o referencial estudado, ossos são representados por valores de intensidade superiores a 200 UH. Portanto, em todos os estudos de caso aplicou-se $T = 200$ inicialmente. O resultado do *global thresholding* aplicado na imagem após difusão anisotrópica é mostrado na Figura 39.

Figura 39 – Segmentação por *global thresholding*. À esquerda, duas fatias da imagem de entrada, à direita, os respectivos resultados do processo de segmentação por *global thresholding*.




Fonte: o autor (2020).

A Figura 39 mostra que o resultado da segmentação é composto por estruturas brancas que representam as substâncias cujas intensidades eram superiores a 200 UH antes da segmentação e por grandes áreas escuras que representam as substâncias que possuíam intensidade inferior ou igual a 200 UH. Em cada uma das imagens são mostrados dois ossos e, no canto inferior esquerdo, a fina linha clara é a mesa na qual o exame foi realizado. Isso exemplifica como a segmentação por *global thresholding* com base nas unidades Hounsfield pode incluir artefatos indesejados.

Em seguida, a imagem binária obtida pela segmentação foi utilizada como entrada em um algoritmo de *labelling* (classificação), utilizado para identificar e classificar cada uma das ROI. A função *label* foi implementada pela biblioteca SciPy e o resultado é apresentado na Figura 40.

Figura 40 – Classificação dos objetos da imagem segmentada. Cada uma das estruturas classificadas é representada por um nível diferente de cinza.




Fonte: o autor (2020).

A Figura 40 apresenta o resultado do processo de classificação em duas fatias da imagem. Cada estrutura identificada é representada por um tom de cinza e classificada por um determinado valor, facilitando a seleção e separação destas estruturas.

Cada objeto foi separado de acordo com as conectividades estabelecidas por um elemento estruturante 3d em forma de cruz, como será explicado a seguir. A seleção do SE deve garantir que cada um dos ossos seja identificado como uma estrutura independente das demais, o que pode ser problemático devido à proximidade entre os

voxels da tíbia e da fíbula especialmente. No primeiro teste de classificação das ROI, um elemento estruturante em forma de cubo ($3 \times 3 \times 3$) foi utilizado, o que fez com que a tíbia e a fíbula fossem classificados como uma única estrutura. A Figura 41 exemplifica o processo de classificação em imagens 2d, que funciona de forma semelhante para imagens 3d, e mostra como a forma do SE pode alterar o resultado do processamento.

Figura 41 – Classificação de estruturas por diferentes elementos estruturantes.




Fonte: o autor (2020).

A imagem à esquerda da Figura 41 representa a imagem de entrada, na qual as áreas brancas enumeradas representam três objetos diferentes (três ossos, por exemplo). Na imagem centralizada, a conectividade entre as estruturas é definida por um elemento estruturante 2d em forma de cruz, cujo centro percorre as fronteiras dos três objetos individualmente e nunca está sobre duas ou mais estruturas ao mesmo tempo, o que resulta na classificação de três estruturas diferentes. No exemplo à direita, as conectividades são definidas por um SE 2d de formato quadrado que, ao percorrer as bordas do objeto número 1, também detecta um *pixel* de borda do objeto número 2, classificando-os como um só objeto, resultando na classificação de apenas duas estruturas distintas na imagem.

Ao final do processo, cada objeto recebe um número de identificação. O resultado ideal, no caso da pré-segmentação dos ossos do joelho, é a classificação de pelo menos 4 estruturas diferentes, correspondentes aos 4 ossos que se pretende segmentar. Contudo, a presença de artefatos não conectados às ROI faz com que o número de objetos classificados seja significativamente maior que 4, o que será mostrado nos tópicos a seguir. O processo é exemplificado na Figura 42.

Figura 42 – Demonstração do processo de classificação e separação dos objetos da imagem.




Fonte: o autor (2020).

Além de exemplificar o processo de classificação e separação dos objetos, já demonstrado na Figura 40, a Figura 42 mostra o elemento estruturante utilizado na classificação de componentes das imagens de todos os indivíduos.

A classificação dos elementos da imagem nas condições descritas gerou um total de 15 estruturas identificadas, das quais quatro correspondem às ROI e o restante a objetos como a mesa de exame e outros pequenos artefatos não conectados aos ossos. A fim de comparação, quando a imagem após 50 iterações de difusão anisotrópica é utilizada como *input*, são classificadas 62 estruturas diferentes.

O histograma da imagem processada foi gerado para auxiliar a identificação das quatro ROI dentre os demais elementos classificados. Após as operações realizadas, é esperado que o histograma seja composto por pelo menos quatro grandes componentes, que representam as ROI, um componente ainda maior, que representa toda a área escura na imagem (cujo valor é igual a 0), e outros pequenos componentes que representam os artefatos classificados não conectados às ROI. A Figura 43 confirma o esperado.

Figura 43 – Histograma da imagem após o processo de classificação.



Fonte: o autor (2020).

Na Figura 43, a imagem à esquerda inclui todos os objetos classificados, na qual o primeiro componente, com valor igual a 0, é muito maior que os demais, fazendo com que os outros componentes mal possam ser observados. Para facilitar a análise dos dados, o componente de número 0 foi descartado do histograma mostrado à direita, no qual os quatro maiores componentes restantes correspondem às ROI, que são os componentes de número 1, 6, 10 e 11. O componente de número 2 corresponde à mesa na qual o paciente foi posicionado.

Com os componentes classificados e separados, em quatro imagens distintas, pôde-se avançar para a etapa seguinte.

6.2.3 Filtragem Morfológica para Correção de Superfícies


Com cada uma das ROI separadas e classificadas, suas superfícies puderam ser analisadas individualmente. Malhas de cada uma delas foram geradas através da versão de Lewiner et al. (2012) do algoritmo *Marching Cubes*, implementada pelo módulo *measure* da biblioteca *scikit-image*. A Figura 44 mostra duas das superfícies geradas.

Vale ressaltar que as malhas mostradas a seguir possuem o único propósito de ilustrar o que está sendo descrito, e que as operações foram aplicadas nas imagens progressivamente geradas ao longo do processo, não nas malhas.

As superfícies demonstradas na Figura 44 possuem descontinuidades e não têm aspecto visual semelhante aos ossos da Figura 34. Como dito ao longo desta pesquisa, imagens médicas podem apresentar uma série de artefatos e imprecisões decorrentes dos

processos de aquisição e formação (**Introdução à Amostragem e Quantização de Imagens**). A proposta desta etapa, portanto, é corrigir estas discontinuidades e aperfeiçoar as imagens através de processamento morfológico.


Figura 44 – Descontinuidades nas superfícies das ROI do Indivíduo 01. Malhas geradas pelo algoritmo Marching Cubes (Lewiner et al., 2012).



Fonte: o autor (2020).

A operação utilizada para a correção das malhas foi o fechamento morfológico, aplicado individualmente a cada uma das imagens de cada objeto. Tal operação foi selecionada por suavizar seções de contorno, unir intervalos estreitos e golfos finos, eliminar pequenos buracos e preencher intervalos no contorno (Gonzalez e Woods, 2006). Um elemento estruturante esférico de raio igual a 9 *pixels* foi utilizado no fechamento morfológico das superfícies. O resultado pode ser visto na Figura 45.

Figura 45 – Superfícies das ROI do Indivíduo 01 antes (fileira de cima) e depois do fechamento morfológico.



Fonte: o autor (2020).

As duas imagens da fileira superior da Figura 45 mostram o interior das malhas geradas a partir das imagens classificadas do fêmur (esquerda) e da fíbula (direita). Pode-se notar que, até a etapa atual, a região interna das ROI não tem sido levada em consideração na análise dos resultados.

As imagens na fileira inferior da Figura 45 mostram que as malhas geradas após o fechamento morfológico não possuem mais as discontinuidades previamente destacadas na Figura 44, enquanto sua forma geral parece inalterada. O tempo necessário para o processamento morfológico de cada uma das 4 imagens foi semelhante, sendo em média 309.4639 segundos.

6.2.4 Segmentação

Como o objetivo do método criado foi definido como a segmentação da camada externa dos ossos, uma nova etapa de segmentação foi aplicada para separação das camadas interna e externa das ROI.


A segmentação foi realizada por *active contour without edges*, implementado com operadores morfológicos pela função *morphological Chan Vese*, disponível no módulo *segmentation* da biblioteca *scikit-image*.

As quatro imagens obtidas após o fechamento morfológico foram utilizadas como *input* e os parâmetros do algoritmo foram selecionados após a realização de experimentos e da comparação de seus resultados. Como dito anteriormente, espera-se que esta etapa de segmentação identifique as superfícies dos objetos de estudo e despreze ruídos tanto dentro quanto fora das ROI.

O número de iterações foi estabelecido em 400 e os valores de λ_1 e λ_2 foram, respectivamente, 0.1 e 2.0. Embora Chan e Vese (2001) e Marquez-Neila, Baumela e Alvarez (2013) recomendem que $\lambda_1 = \lambda_2 = 1$, notou-se que, neste caso, atribuir os valores $\lambda_1 = 0.1$ e $\lambda_2 = 2.0$ faria com que o algoritmo desprezasse a região interna do objeto a ser segmentado e segmentaria precisamente sua superfície. Os demais parâmetros não foram alterados e, por fim, o algoritmo foi aplicado separadamente nas imagens dos quatro ossos estudados.


Os resultados obtidos são mostrados na Figura 46, Figura 47, Figura 48 e Figura 49, que mostram as malhas do fêmur, da patela, da tíbia e da fíbula, respectivamente, do Indivíduo 01. Nota-se que o interior dos ossos está completamente vazio, enquanto suas estruturas externas estão preservadas.

Figura 46 – Fêmur do Indivíduo 01, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.




Fonte: o autor (2020).

Figura 47 – Patela do Indivíduo 01, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.



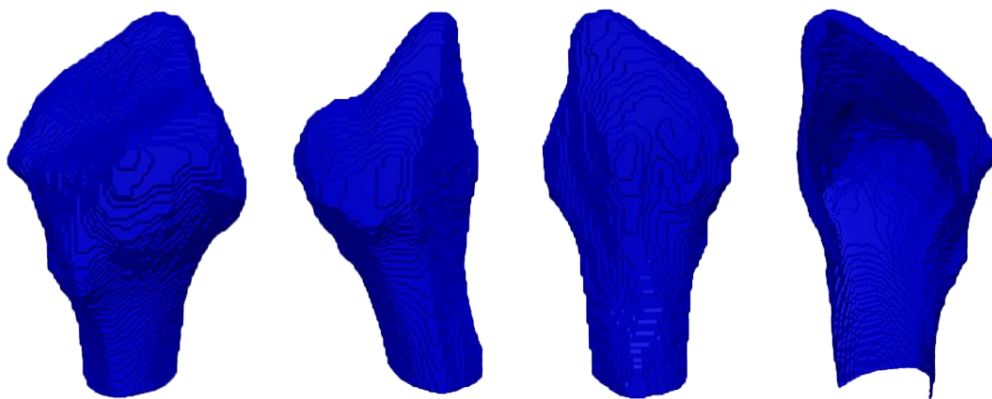
Fonte: o autor (2020).

Figura 48 – Tíbia do Indivíduo 01, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.



Fonte: o autor (2020).

Figura 49 – Fíbula do Indivíduo 01, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.



Fonte: o autor (2020).

Esse é o procedimento de maior custo computacional aplicado na metodologia proposta, e o tempo de processamento de cada imagem foi significativamente maior que o de qualquer outro processo realizado até então. O tempo necessário para a segmentação dos ossos do Indivíduo 01 está descrito na Tabela 6.

Tabela 6 – Duração do processo de segmentação das ROI do Indivíduo 01.

Osso	Duração do processamento (segundos)
Fêmur	8801.7293
Patela	8800.8599
Tíbia	8794.3345
Fíbula	8760.3253

Fonte: o autor (2020).

6.2.5 Refinamento e exportação

As malhas foram suavizadas por um filtro Gaussiano para que suas superfícies fossem uniformizadas. As malhas filtradas foram salvas em formato STL e importadas no *software* Blender 3d (Blender Foundation, 2002), no qual foram tratadas manualmente para que adquirissem aspecto realista. No programa, a única alteração realizada na malha foi a conversão dos triângulos que a compunham para quadriláteros, o que diminui o número geral de polígonos sem alterar significativamente o formato geral da malha (Blender 2.83 Manual, 2020). Antes da conversão, os ossos do Indivíduo 01 eram

formados por 833,966 polígonos. Após a conversão, esse valor caiu para 502,063 polígonos, o que diminuiu drasticamente o custo computacional necessário para a manipulação do modelo. O resultado obtido após a renderização com a ferramenta Cycles do próprio Blender é mostrado na Figura 50.

Figura 50 – Ossos do joelho do Indivíduo 01 renderizados no Blender 3d.



Fonte: o autor (2020).

6.3 Estudo de Caso: Indivíduo 02

6.3.1 Preparação dos Dados


O exame do Indivíduo 02 foi gerado de forma similar ao do Indivíduo 01, e os *voxels* da imagem também tiveram que ser reamostrados. Na imagem original, a distância entre os *pixels* nos eixos X e Y é de aproximadamente 0.39 mm, enquanto no eixo Z a distância é de 0.6 mm. Portanto, o fator de reamostragem aplicado foi de 0.6/0.39. O resultado é uma imagem com 386 fatias (135 a mais que a imagem original), cada uma com aproximadamente 0.2540 mm de espessura. O tempo de processamento foi de 32.08 segundos.

6.3.2 Pré-segmentação da Imagem

Em seguida, o filtro de difusão anisotrópica com base na função de *Tukey* foi aplicado à nova imagem através de 250 iterações. O processamento durou 1314.5223 segundos. As operações de *global thresholding*, com $T = 200$, e *labelling* foram executadas, e 181 objetos foram classificados (a fim de comparação, 15 objetos foram classificados após as mesmas operações terem sido realizadas no Indivíduo 01).

Dentre os 181 objetos classificados, 4 deles correspondiam às ROI. Contudo, ao gerar a visualização 3d destas estruturas, pôde-se perceber que as discontinuidades eram significativamente maiores que as presentes nas ROI do Indivíduo 01 após o processo de classificação, como ilustra a Figura 51, que mostra grandes falhas nas superfícies dos ossos, havendo inclusive a presença de um artefato conectado à malha da fíbula (Figura 51 (d)) do Indivíduo 02.

Figura 51 – ROI do Indivíduo 02 classificadas e separadas.



Fonte: o autor (2020).

Após investigação, pôde-se perceber que as intensidades em determinadas regiões das bordas dos ossos da imagem eram menores que o esperado (200 UH), mesmo antes do processo de difusão anisotrópica. A Figura 52 mostra parte de uma camada da imagem antes e depois da difusão anisotrópica, onde a borda de parte do fêmur foi evidenciada.

Figura 52 – Visualização de parte do fêmur em uma das camadas da imagem. São mostradas a imagem original, e a imagem após 50 e 250 iterações de difusão anisotrópica, respectivamente.



Fonte: o autor (2020).

Nota-se, mesmo na imagem original, que as intensidades da borda evidenciada são pouco distinguíveis quando comparadas às estruturas ao seu redor, o que fez com que o processo de difusão anisotrópica tornasse as fronteiras ainda menos evidentes ao tentar uniformizar dois objetos diferentes.

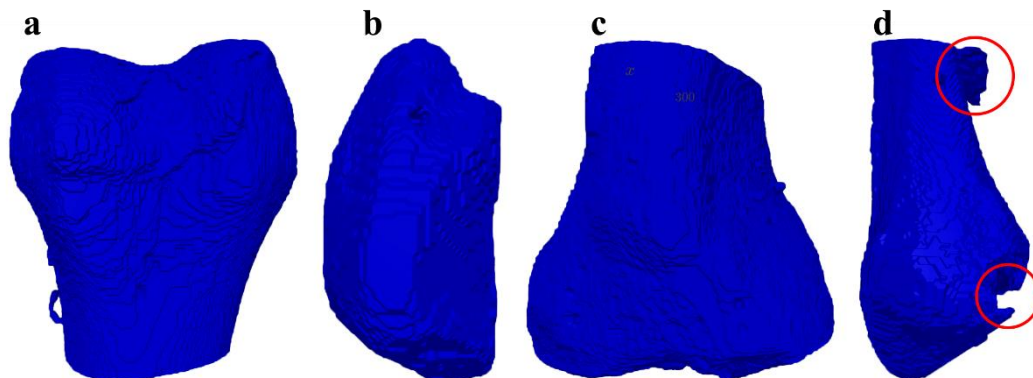
A primeira alternativa testada para solucionar o problema foi classificar e separar as estruturas antes da difusão anisotrópica, esperando que as intensidades das bordas da imagem original respeitassem os valores de UH propostos pela bibliografia analisada sobre o tema. Porém, sem a difusão anisotrópica, o processo de *labelling* classificou 1501 objetos diferentes, dentre os quais estavam as ROI.

As malhas geradas a partir deste teste não apresentaram melhora significativa quando comparadas às mostradas na Figura 51. Embora as discontinuidades fossem menores em algumas regiões, a maior parte dos buracos foi mantida e novos artefatos foram adicionados.

O segundo teste baseou-se na alteração do limiar aplicado na segmentação por *global thresholding*. Analisando-se a área mostrada na Figura 52, percebeu-se que as intensidades próximas às bordas possuíam valores mais baixos que 200 UH. O valor médio das intensidades encontrado na borda mostrada na imagem à direita da Figura 52, por exemplo, foi de 92.7303 UH.

Um teste foi realizado usando esse valor médio como base para o *thresholding* e, em seguida, os objetos da imagem foram classificados e separados. O resultado obtido pode ser visto na Figura 53.

Figura 53 – ROI do Indivíduo 02 classificadas após mudança no parâmetro do *thresholding*.



Fonte: o autor (2020).

Com exceção de um grande buraco e a presença de um artefato na malha da fíbula (d), as estruturas geradas possuem discontinuidades menos severas que as obtidas após o primeiro teste da pré-segmentação. Os buracos nas malhas da Figura 53 são menores, inclusive, que os vistos nas imagens do Indivíduo 01 após a classificação. Embora pareça um fator positivo, isso gerou problemas importantes para as etapas seguintes, como a adição de artefatos e novas falhas nas superfícies das ROI. Estas imagens foram submetidas ao processo seguinte, no qual seus problemas serão abordados em detalhes.


6.3.3 Filtragem Morfológica para Correção de Superfícies

O processamento realizado nesta etapa ocorreu de acordo com os mesmos parâmetros aplicados para o Indivíduo 01, com exceção do tamanho do SE utilizado: as ROI foram submetidas ao fechamento morfológico por um SE esférico de raio igual a 2 *pixels*, com o intuito de preencher pequenos buracos e discontinuidades na malha. Como esperado, parte da malha dos modelos foi corrigida enquanto suas estruturas internas foram mantidas.

O raio do elemento estruturante aplicado no fechamento morfológico das imagens do Indivíduo 02 foi menor que o aplicado no fechamento morfológico das imagens do Indivíduo 01 por que as discontinuidades nas malhas do Indivíduo 02 após a pré-segmentação, em geral, eram muito menores. Isso aconteceu graças a escolha de um limiar muito menor para o processo de *global thresholding*, que fez com que mais estruturas fossem classificadas como componentes das ROI.

Contudo, esse limiar reduzido levou à inclusão de muitos artefatos nas imagens das ROI. Estes artefatos, muitas vezes conectados às bordas das estruturas, fizeram com que os modelos obtidos após o fechamento morfológico ainda apresentassem irregularidades significativas. A Figura 54 mostra o resultado da operação.

Figura 54 – Superfícies das ROI do Indivíduo 02 depois do fechamento morfológico. São mostrados, em destaque, artefatos nos ossos e um buraco na fíbula.



Fonte: o autor (2020).

Quando comparadas às malhas do Indivíduo 01 mostradas na Figura 45, pode-se perceber que as malhas da Figura 54 são menos uniformes, além de ainda haver um

grande buraco e um grande artefato na malha da fíbula. Aliás, o fechamento morfológico tornou o artefato conectado à fíbula ainda maior.


O processo de erosão morfológica foi aplicado para a remoção dos pequenos artefatos conectados às malhas. Porém, a aplicação da erosão gerou novas imperfeições na malha. Alguns buracos foram aumentados e os artefatos não foram removidos. Acredita-se que o motivo da falha tenha sido a irregularidade da malha e a presença de componentes em seu interior, que fez com que o processo de erosão ocorresse de forma exagerada.

Portanto, com o propósito de simplificar a malha, eliminar seu conteúdo interno e dar mais controle à aplicação da erosão morfológica, optou-se por avançar para a etapa de segmentação. As imagens após fechamento morfológico foram utilizadas como *input* para o processo de segmentação.

6.3.4 Segmentação


A segmentação foi realizada através do algoritmo *morphological Chan Vese*, como proposto inicialmente. Novamente, foram executadas 400 iterações, e os valores de λ_1 e λ_2 foram, respectivamente, 0.1 e 2.0. O resultado da operação é apresentado na Figura 55, Figura 56, Figura 57 e Figura 58.

Figura 55 – Fêmur do Indivíduo 02, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.




Fonte: o autor (2020).

Figura 56 – Patela do Indivíduo 02, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.




Fonte: o autor (2020).

Figura 57 – Tíbia do Indivíduo 02, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.



Fonte: o autor (2020).

Figura 58 – Fíbula do Indivíduo 02, segmentada por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. Os destaques, em vermelho, mostram as falhas na malha segmentada.



Fonte: o autor (2020).

As figuras do fêmur, da patela e da tíbia mostram que a segmentação foi executada da maneira esperada nestas imagens. A malha externa foi mantida enquanto a estrutura

interna foi eliminada. Os pequenos artefatos presentes nas bordas do fêmur e da tíbia também foram mantidos.

A segmentação da fíbula manteve os grandes buracos na superfície e não eliminou completamente sua estrutura interna, além de ter preservado um grande artefato. Embora esperado, esse resultado não pode ser considerado satisfatório, pois as etapas seguintes da metodologia proposta não são adequadas para a correção de grandes irregularidades como as citadas.

Acredita-se que, para a segmentação adequada da tíbia, seria necessário retornar à segunda etapa da metodologia, testando novos valores para o procedimento de *global thresholding* até que não houvesse mais grandes descontinuidades no objeto classificado, testando diferentes aplicações de filtros morfológicos para correção de superfície e remoção de grandes estruturas. Essa questão será abordada novamente no tópico de Resultados e Discussões.

O tempo necessário para o processo de segmentação das 4 ROI é mostrado na Tabela 7.

Tabela 7 – Duração do processo de segmentação das ROI do Indivíduo 02.

Osso	Duração do processamento (segundos)
Fêmur	8945.7773
Patela	8773.0649
Tíbia	8768.9756
Fíbula	8766.3983

Fonte: o autor (2020).


6.3.5 Refinamento e Exportação

Como as malhas do fêmur e da tíbia ainda possuem pequenos artefatos, mostrados em diversas figuras dos últimos tópicos, o primeiro objetivo do refinamento foi remover esses artefatos. Como dito anteriormente, a erosão morfológica é capaz de eliminar pequenos objetos da imagem, e foi aplicada nestes dois modelos.

Para a correção da malha do fêmur, a erosão morfológica foi aplicada através de um elemento estruturante esférico com 5 *pixels* de raio. O processamento do fêmur levou 58.3151 segundos para ser concluído. A tíbia apresentava artefatos maiores que os do fêmur, portanto, a erosão foi aplicada com um elemento estruturante esférico de raio igual

a 9 *pixels*. O processamento da tíbia durou 326.8080 segundos. Os resultados são mostrados na Figura 59.

Figura 59 – Malhas do fêmur e da tíbia, respectivamente, após erosão morfológica para remoção de pequenos artefatos.




Fonte: o autor (2020).

A Figura 59 mostra que as malhas agora não possuem mais os pequenos artefatos que estavam conectados a elas, mostrando que, neste caso, foi vantajoso aplicar a erosão morfológica após o processo de segmentação.

A malha da fíbula, porém, não pôde ser corrigida pela aplicação das mesmas técnicas. Como dito anteriormente, acredita-se que a melhor alternativa para a segmentação da fíbula do Indivíduo 02 seja abordá-la individualmente, focando especificamente na segmentação desta estrutura desde o começo do processo.

As malhas foram suavizadas por um filtro Gaussiano para que suas superfícies fossem uniformizadas. As malhas filtradas foram salvas em formato STL e importadas para o *software* Blender 3d, no qual foram tratadas manualmente para que adquirissem aspecto realista. As técnicas aplicadas nesta etapa de finalização foram exatamente as mesmas aplicadas para o Indivíduo 01. O resultado é mostrado na Figura 60.

Figura 60 – Ossos do joelho do Indivíduo 02 renderizados no Blender 3d.



Fonte: o autor (2020).

6.4 Estudo de Caso: Indivíduo 03

6.4.1 Preparação dos Dados

Assim como nos casos anteriores, a imagem do Indivíduo 03 foi reamostrada através da operação *zoom*. A imagem de entrada possui 310 camadas, a distância entre os *pixels* nos eixos X e Y é de aproximadamente 0.39 mm, e a espessura das camadas é de 0.75 mm. Portanto, o fator de reamostragem aplicado foi de 0.75/0.39. A imagem de saída possui 595 camadas, cada uma com aproximadamente 39,0756 mm de espessura. O tempo de processamento foi de 47.82 segundos.

6.4.2 Pré-Segmentação


A imagem reamostrada foi submetida à difusão anisotrópica sob os mesmos parâmetros aplicados nos casos anteriores. Após 250 iterações, a imagem filtrada foi utilizada como entrada para o processo de *global thresholding*. O tempo necessário para a operação da difusão anisotrópica foi de 1164.5706 segundos.

O limiar aplicado para a segmentação foi igual a 200 UH. A imagem binária foi então submetida ao *labelling*, e um elemento estruturante 3d em forma de cruz foi utilizado para definir as conectividades, resultando em 31 objetos classificados.

As malhas classificadas das ROI foram geradas e analisadas. A malha do fêmur apresentava um buraco relativamente grande, e um artefato foi classificado como parte da tíbia. As duas características descritas podem ser vistas em destaque na Figura 61.

Como as falhas apresentadas no modelo do fêmur são relativamente grandes, acredita-se que seja preferível alterar o valor aplicado na operação de *global thresholding* a tentar corrigir o modelo gerado com operações morfológicas. Com base no processamento do Indivíduo 02, espera-se que um limiar mais baixo faça com que mais estruturas sejam classificadas como parte do fêmur, preenchendo suas imperfeições ou parte delas.

Figura 61 – Malhas do fêmur e da tíbia, respectivamente, após pré-segmentação. As áreas destacadas no fêmur mostram dois grandes buracos e um artefato pode ser visto na malha da tíbia.




Fonte: o autor (2020).

A pré-segmentação das imagens do Indivíduo 02 exigiu que o limiar aplicado ao *global thresholding* fosse muito mais baixo que as 200 UH sugeridas pela literatura. No caso do Indivíduo 03, as discontinuidades na malha do fêmur não são tão severas, portanto, o valor do limiar foi definido após um teste empírico, no qual este valor foi decrescido de 10 UH até que a malha obtida possuísse menos falhas.

Selecionando estruturas com intensidade maior que 170 UH e desprezando as demais, o número de grandes buracos na superfície do fêmur, da tíbia e da fíbula foi reduzido. Porém, o artefato presente na tíbia foi mantido.

Os resultados obtidos após a pré-segmentação das ROI do Indivíduo 03 são apresentados na Figura 62.

Figura 62 – ROI do Indivíduo 03 classificadas e separadas.




Fonte: o autor (2020).

A Figura 62 mostra que a pré-segmentação das imagens do Indivíduo 03 gerou malhas aparentemente uniformes, com poucos e pequenos buracos. Portanto, estas imagens foram submetidas à etapa seguinte.

6.4.3 Filtragem Morfológica para Correção de Superfícies

Cada uma das imagens foi individualmente submetida a fechamento morfológico, realizado por um elemento estruturante esférico com 9 *pixels* de raio, o que preencheu pequenos buracos e uniu superfícies próximas em cada uma das ROI. A patela não foi envolvida no processamento morfológico pois a pré-segmentação desta estrutura não gerou artefatos ou defeitos aparentes em sua superfície. O resultado da operação é demonstrado na Figura 63.

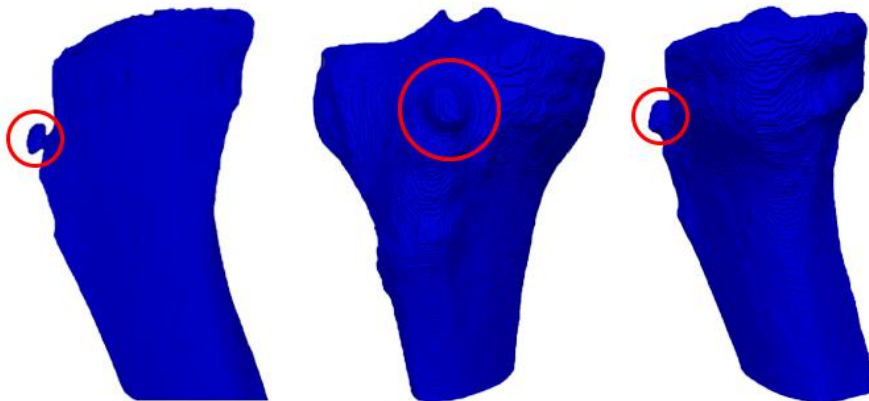
Figura 63 – Superfícies das ROI do Indivíduo 03 depois do fechamento morfológico.



Fonte: o autor (2020).

A Figura 63 mostra o resultado do fechamento morfológico. As malhas obtidas tiveram suas pequenas descontinuidades corrigidas. Contudo, o artefato conectado à malha da tíbia não foi apenas mantido, mas também aumentado, como mostra a Figura 64.

Figura 64 – Artefato conectado à malha da tíbia antes e depois do fechamento morfológico.




Fonte: o autor (2020).

A Figura 64 mostra que o fechamento morfológico uniu ainda mais a malha da tíbia ao artefato, o que era esperado devido aos resultados obtidos em condições semelhantes no estudo de caso anterior.

Como alternativa, a erosão morfológica foi aplicada à malha da tíbia pré-segmentada. O objetivo foi analisar como o processo agiria sobre a malha e especialmente sobre o artefato. A Figura 65 mostra os resultados obtidos.

Figura 65 – Erosão morfológica da malha da tíbia. Tamanho do raio dos elementos estruturantes utilizados, da esquerda para a direita: 3, 5, 7 e 9 pixels.



Fonte: o autor (2020).

A Figura 65 mostra o resultado da erosão morfológica aplicada à malha da tíbia após a pré-segmentação. Percebe-se que a erosão age sobre o artefato. No entanto, como a malha ainda possui pequenas discontinuidades e estruturas em seu interior, a erosão morfológica não acontece apenas sobre o artefato e elimina progressivamente qualquer estrutura menor que o elemento estruturante aplicado.

Comparando os resultados das duas operações, e com base nos testes realizados nos estudos de caso anteriores, optou-se por utilizar as imagens após fechamento morfológico, mostradas na Figura 63, como *input* para o processo de segmentação.

O tempo de processamento para o fechamento morfológico do fêmur, da fíbula e da tíbia são mostrados na Tabela 8.

Tabela 8 – Duração do processo de fechamento morfológico do fêmur e da fíbula do Indivíduo 03.


Osso	Duração do processamento (segundos)
Fêmur	499.6191
Fíbula	517.0441
Tíbia	501.8543

Fonte: o autor (2020).

6.4.4 Segmentação


A segmentação por *morphological Chan Vese* foi aplicada seguindo os mesmos parâmetros dos dois últimos estudos de caso apresentados, e o resultado obtido é apresentado nas Figura 66, Figura 67, Figura 68 e Figura 69.

Figura 66 – Fêmur do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. O destaque, em vermelho, mostra parte da área interna do osso, também segmentada.




Fonte: o autor (2020).

Figura 67 – Patela do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.




Fonte: o autor (2020).

Figura 68 – Tíbia do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. O destaque, em vermelho, mostra parte da área interna do osso, também segmentada.



Fonte: o autor (2020).

Figura 69 – Fíbula do Indivíduo 03, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.



Fonte: o autor (2020).

O tempo necessário para a segmentação das imagens do Indivíduo 03 são mostrados na Tabela 9.

Tabela 9 – Duração do processo de segmentação das ROI do Indivíduo 03.

Osso	Duração do processamento (segundos)
Fêmur	13638.5102
Patela	13638.6201
Tíbia	13631.8566
Fíbula	13608.0694

Fonte: o autor (2020).

6.4.5 Refinamento e Exportação

As malhas foram suavizadas por um filtro Gaussiano para que suas superfícies fossem uniformizadas. As malhas filtradas foram salvas em formato STL e importadas para o *software* Blender 3d, no qual foram tratadas para que adquirissem aspecto realista. As técnicas aplicadas nesta etapa de finalização foram exatamente as mesmas aplicadas para o Indivíduo 01. O resultado é mostrado na Figura 70.

Figura 70 – Ossos do joelho do Indivíduo 03 renderizados no Blender 3d.



Fonte: o autor (2020).

6.5 Estudo de Caso: Indivíduo 04

6.5.1 Preparação dos Dados

A imagem original do Indivíduo 04 tem 356 camadas (eixo Z), com espessura de 0.6 mm, e a distância entre os *pixels* nos eixos X e Y é de aproximadamente 0.4 mm. Assim como nos casos anteriores, a imagem original foi reamostrada. Após 44.6969


segundos, o processamento gerou uma imagem de saída com 533 camadas, cada uma com espessura aproximada de 0.4 mm.

6.5.2 Pré-Segmentação

Utilizando a imagem reamostrada como *input*, a difusão anisotrópica foi aplicada com 250 iterações, como nos casos anteriores. Esse processamento foi executado em 1049.0016 segundos. A imagem filtrada foi submetida aos processos de *global thresholding* e classificação, e então as ROI foram separadas. Foram encontrados 50 componentes após o *labelling*.

A geração das malhas das ROI classificadas mostrou que o fêmur apresentava vários pequenos buracos, além de uma grande descontinuidade, o modelo da fíbula e da tíbia também possuíam um único grande buraco cada um. Os casos descritos são apresentados em destaque na Figura 71. A patela foi bem classificada, e sua superfície é visualmente uniforme.

Figura 71 – ROI do Indivíduo 04. Fêmur, tíbia e fíbula após primeira tentativa de pré-segmentação. Os contornos em vermelho destacam as falhas geradas nos modelos.



Fonte: o autor (2020).


Após teste semelhante ao aplicado no caso do Indivíduo 03, o valor escolhido para o processo de *global thresholding* foi reduzido para 160 UH e os objetos da imagem foram classificados novamente. Novas malhas do fêmur, da tíbia e da fíbula foram geradas e analisadas. Os resultados obtidos possuíam menos descontinuidades e buracos quando

comparados aos gerados anteriormente, portanto, juntamente com a patela, foram submetidos à etapa seguinte.

6.5.3 Filtragem Morfológica para Correção das Superfícies.

O processamento morfológico foi aplicado em todos os modelos obtidos após a pré-segmentação, com exceção da patela, cuja superfície foi gerada sem falhas aparentes. Como nos casos anteriores, o fechamento morfológico foi aplicado a partir de um elemento estruturante esférico de raio igual a 9 *pixels*. O resultado do procedimento, juntamente com a patela, pode ser visto na Figura 72.

Figura 72 – Superfícies das ROI do Indivíduo 04 depois do fechamento morfológico. A patela não precisou ser filtrada morfológicamente.



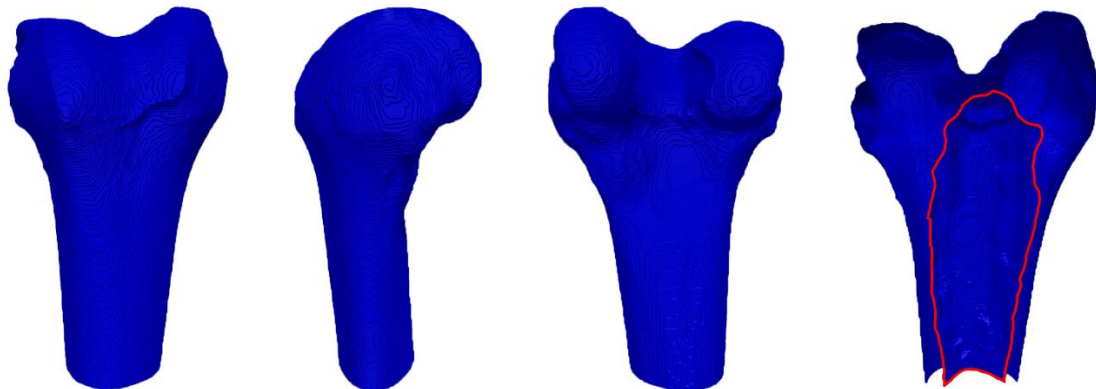
Fonte: o autor (2020).

Com suas superfícies íntegras, os modelos foram submetidos ao processo final de segmentação.

6.5.4 Segmentação


Os parâmetros aplicados na segmentação das imagens do Indivíduo 04 foram os mesmos aplicados nos três estudos de caso anteriores. O resultado da operação é apresentado na Figura 73, Figura 74, Figura 75 e Figura 76.

Figura 73 – Fêmur do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna. O destaque, em vermelho, mostra parte da área interna do osso, também segmentada.




Fonte: o autor (2020).

Figura 74 – Patela do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.




Fonte: o autor (2020).

Figura 75 – Tíbia do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.



Fonte: o autor (2020).

Figura 76 – Fíbula do Indivíduo 04, segmentado por morphological Chan Vese. Da esquerda para a direita: vista anterior, vista lateral, vista posterior e vista interna.



Fonte: o autor (2020).

A Tabela 10 mostra a duração do processo de segmentação das imagens do Indivíduo 04.

Tabela 10 – Duração do processo de segmentação das ROI do Indivíduo 04.

Osso	Duração do processamento (segundos)
Fêmur	12085.3912
Patela	12077.2111
Tíbia	12103.4089
Fíbula	12119.9692

Fonte: o autor (2020).

6.5.5 Refinamento e exportação

As malhas foram suavizadas por um filtro Gaussiano para que suas superfícies fossem uniformizadas. As malhas filtradas foram salvas em formato STL e importadas para o *software* Blender 3d, no qual foram tratadas para que adquirissem aspecto realista. As técnicas aplicadas nesta etapa de finalização foram exatamente as mesmas aplicadas para o Indivíduo 01. O resultado é mostrado na Figura 77.

Figura 77 – Ossos do joelho do Indivíduo 04 renderizados no Blender 3d.



Fonte: o autor (2020).

Capítulo 7 - RESULTADOS E DISCUSSÕES

A metodologia proposta é formada por cinco etapas principais: preparação dos dados, pré-Segmentação, filtragem morfológica, segmentação e refinamento e exportação. Em cada uma das etapas, uma ou mais ferramentas foram utilizadas para preparar as imagens para a etapa seguinte até a obtenção do resultado esperado.

Cada um dos quatro indivíduos foi abordado individualmente em um estudo de caso e, embora a metodologia proposta tenha sido aplicada a todos, situações específicas exigiram alterações pontuais. Cada etapa será discutida individualmente nos tópicos a seguir.

7.1 Preparação dos dados

A preparação de todas as imagens foi feita a partir da mesma lógica. O único parâmetro diferente entre os indivíduos foi o fator de reamostragem, que variou de acordo com o tamanho de cada imagem, como mostra a Tabela 11.

Tabela 11 – Reamostragem dos dados.

Indivíduo	Quantidade original de fatias	Fator de reamostragem	Quantidade final de fatias
Indivíduo 01	251	0.6/0.39	386
Indivíduo 02	251	0.6/0.39	386
Indivíduo 03	310	0.75/0.39	595
Indivíduo 04	356	0.6/0.4	533

Fonte: o autor (2020).

7.2 Pré-segmentação

O processo de difusão anisotrópica com base na função de Tukey foi aplicado sob os mesmos parâmetros (250 iterações) em todos os casos. O resultado ideal, neste caso, foi definido como a obtenção de imagens nas quais as intensidades dos *pixels* de borda tenham sido preservadas enquanto a intensidade no interior das estruturas tenha sido uniformizada, facilitando a distinção entre os componentes da imagem.

A segmentação por *global thresholding* foi o processo que mais sofreu alterações entre os estudos de caso. Apenas no caso do Indivíduo 01 o limiar sugerido pela literatura para segmentação de ossos, 200 UH, gerou os resultados esperados, ou seja, gerou a segmentação dos ossos da imagem sem adicionar artefatos ou remover estruturas relevantes. Para obter resultados semelhantes aos do Indivíduo 01, o limiar utilizado na pré-segmentação das demais imagens é apresentado na Tabela 12.

Tabela 12 – Limiares aplicados durante a pré-segmentação por *global thresholding*.

Indivíduo	Limiar aplicado (UH)
Indivíduo 01	200
Indivíduo 02	98.73
Indivíduo 03	170
Indivíduo 04	160

Fonte: o autor (2020).

Como a pré-segmentação foi realizada a partir de valores distintos, os resultados obtidos na etapa de classificação (*labelling*) também foram diferentes. Após a segmentação por *global thresholding*, as imagens do Indivíduo 01 eram compostas por 15 estruturas, das quais 4 correspondiam aos ossos, as imagens do Indivíduo 02 possuíam 211 estruturas, as imagens do Indivíduo 03 continham 31 estruturas e as imagens do Indivíduo 04 eram compostas por 50 estruturas.

Apesar das grandes diferenças apresentadas, ao final desta etapa os resultados obtidos entre os estudos de caso eram visualmente semelhantes, com exceção de alguns casos: a malha da fíbula do Indivíduo 02, mostrada na Figura 51, apresentava um grande buraco e um artefato conectado a ela, e a malha da tíbia do Indivíduo 03 também possuía um artefato em sua estrutura (Figura 64).

7.3 Filtragem Morfológica

Nos casos em que as imagens geradas pela pré-segmentação possuíam poucas descontinuidades ou pequenos buracos, o fechamento morfológico foi capaz de corrigir as malhas. Uma malha considerada pronta para o processo de segmentação não poderia possuir quaisquer buracos ou descontinuidades em sua superfície externa. Essa condição foi definida após os testes iniciais mostrarem que, nessas condições, a segmentação por *Morphological Chan-Vese* segmentaria a camada externa dos ossos e desprezaria suas estruturas internas.

Foi possível notar que, quanto menor o limiar utilizado na pré-segmentação, maior foi o número de artefatos adicionados à imagem. A imagem do Indivíduo 02, à qual o menor limiar foi aplicado, gerou malhas com pequenos artefatos no fêmur e na tíbia, e uma malha com grandes defeitos na fíbula. A erosão morfológica foi testada para a remoção de artefatos. Contudo, os testes mostraram que a erosão morfológica deveria ser aplicada após o processo de segmentação para gerar os resultados esperados, como mostraram os testes apresentados na Figura 65.

O tamanho dos elementos estruturantes aplicados variou conforme o tamanho da área que esperava-se corrigir. Embora a forma esférica dos SE tenha sido aplicada igualmente em todos os processos de correção por processamento morfológico, falhas maiores exigiram elementos estruturantes maiores. Os raios dos SE esféricos variaram de 2 a 9 *pixels*.

7.4 Segmentação

Como já mencionado, o processo de segmentação por *Morphological Chan Vese* é o processo de maior custo computacional da metodologia proposta. A duração média para a segmentação de todas as ROI de cada indivíduo mostra que há relação entre o tamanho da imagem e a duração do processamento. A Tabela 133 mostra essa relação.

Tabela 13 – Relação entre duração média do processamento e tamanho das imagens.

Indivíduo	Duração média do processamento	Tamanho da imagem (x,y,z)
01	2 horas e 26 minutos	512, 512, 386
02	2 horas e 26 minutos	512, 512, 386
03	3 horas e 46 minutos	512, 512, 595
04	3 horas e 21 minutos	512, 512, 533

Fonte: o autor (2020).

Embora os parâmetros tenham sido os mesmos, o processamento gerou resultados diferentes entre os estudos de caso. A segmentação das imagens do Indivíduo 01 ocorreu conforme o esperado: somente a camada externa dos ossos foi preservada e o seu interior ficou completamente vazio. No caso do Indivíduo 02, os ossos também foram segmentados e o resultado foi semelhante ao do Indivíduo 01, com exceção da fíbula, que manteve um grande buraco e um artefato conectados à sua malha.

Nos estudos de caso dos Indivíduos 03 e 04, a segmentação das imagens gerou a camada externa das malhas, mas o fêmur de ambas e a tíbia do Indivíduo 03 tiveram sua camada *interna* segmentada, como mostra a Figura 66, Figura 68 e Figura 73. A análise destes casos mostrou que não havia *pixels* conectando as malhas externas às internas.

Não se sabe exatamente por que as malhas internas foram segmentadas em determinados casos e não nos demais, uma vez que os parâmetros aplicados no processo de segmentação foram exatamente os mesmos. Acredita-se que a integridade das estruturas no interior dos ossos possa ter influenciado estes resultados: nos casos em que as estruturas internas possuíam menos descontinuidades, talvez devido ao limiar utilizado na pré-segmentação, elas teriam sido mais bem segmentadas pelo algoritmo.

Apesar de alguns resultados imprevistos, a etapa de segmentação ocorreu de forma esperada para a maioria das imagens, gerando a malha externa dos ossos de cada Indivíduo.

7.5 Refinamento e Exportação

A etapa de refinamento foi acrescentada para corrigir pequenas falhas que ainda poderiam estar presentes nas imagens e para filtrar as malhas, que até então possuíam aspecto irregular após geradas pelo algoritmo *Marching Cubes*.

As imagens do fêmur e da tíbia do Indivíduo 02 apresentavam pequenos artefatos conectados aos ossos após a segmentação. Esses artefatos foram removidos com sucesso por meio do processo de erosão morfológica, como mostra a Figura 59. Porém, os artefatos na fíbula do Indivíduo 02 e na tíbia do Indivíduo 03 eram muito grandes e não puderam ser removidos por erosão morfológica. O resultado dessa operação alterou as malhas inteiras, não somente os artefatos, gerando resultados semelhantes aos mostrados na Figura 65.

As imagens dos demais indivíduos não exigiram quaisquer medidas de refinamento, com exceção do filtro Gaussiano aplicado para suavização das malhas. Todas as imagens foram, então, exportadas em formato STL.

Capítulo 8 - CONCLUSÃO

Ao longo deste trabalho foram apresentadas as ferramentas que compuseram a metodologia desenvolvida para auxiliar o processo de segmentação das superfícies dos ossos do joelho humano a partir de imagens de tomografia computadorizada. A metodologia proposta foi definida a partir de testes e análise dos resultados obtidos a cada nova etapa do processamento.

O resultado esperado correspondia à geração de modelos 3d que se assemelhassem às estruturas reais. Para que os resultados fossem considerados satisfatórios, estes modelos deveriam ser compostos apenas pelo segmento externo dos ossos da articulação do joelho, sem a presença de artefatos.

A abordagem individual das imagens foi capaz de gerar o resultado esperado na maioria dos casos, mas mostrou que a metodologia proposta precisa ser adaptada em situações específicas. Dos 16 modelos obtidos ao final dos estudos:

- doze correspondiam às superfícies dos ossos, como esperado,
- três resultaram na segmentação da superfície externa e interna dos ossos, sendo que um deles também continha um objeto indesejado que não pôde ser removido a partir das mesmas técnicas aplicadas nos demais casos,
- um modelo apresentou uma descontinuidade e um artefato que não puderam ser removidos pelas mesmas técnicas aplicadas aos demais objetos.

A segmentação de imagens de TC com base nas unidades Hounsfield se mostrou possível. Contudo, os parâmetros utilizados no processo de *global thresholding* não corresponderam ao esperado e tiveram que ser readequados a cada um dos estudos de caso realizados. A aplicação de um limiar igual a 200 UH gerou o resultado esperado na pré-segmentação de um dos quatro estudos de caso realizados.

A filtragem por difusão anisotrópica com base na função de Tukey foi determinante para que o processo de classificação e separação das ROI fosse bem sucedido. Nesta pesquisa, na qual mais de um objeto da mesma imagem deveria ser segmentado, a diferenciação entre estes objetos foi de extrema importância.

O processamento morfológico de imagens se mostrou um recurso eficiente para a correção de pequenos problemas gerados pela segmentação por *global thresholding*. O fechamento morfológico foi capaz de preencher pequenos buracos nas malhas, e a erosão morfológica, quando aplicada após o processo de segmentação final, foi capaz de remover pequenos artefatos das imagens.

O algoritmo de segmentação por *active contour without edges* implementado por operadores morfológicos gerou os resultados esperados para a maioria dos casos após a seleção de parâmetros específicos que, quando definidos, foram aplicados igualmente a todos os casos. A operação é computacionalmente custosa. Porém, com base nos resultados obtidos, acredita-se que recortar as imagens com base na região de interesse possa diminuir significativamente o tempo de processamento.

Infelizmente, os resultados não puderam ser submetidos a testes quantitativos para análise de sua eficiência e eficácia. A qualidade dos resultados obtidos foi baseada em referências visuais e na seleção criteriosa dos parâmetros aplicados.

8.1 Direções Futuras

- A quantidade de estudos de caso desenvolvidos por este estudo foi muito pequena para que a técnica seja considerada adequada ou não para os fins estabelecidos. A aplicação do método a um número maior de imagens poderia comprovar ou não sua eficiência.
- Acredita-se que seria importante comparar ao menos um dos resultados obtidos a outros modelos segmentados manualmente por especialistas. A possibilidade de comparar os resultados a um *ground truth* poderia comprovar ou não a eficácia do método proposto.

REFERÊNCIAS BIBLIOGRÁFICAS

A.A. Ali, S.S. Shalhoub, A.J. Cyr, C.K. Fitzpatrick, L.P. Maletsky, P.J. Rullkoetter and K.B. Shelburne. 2016. *Validation of predicted patellofemoral mechanics in a finite element model of the healthy and cruciate-deficient knee*. J Biomech 49:302-9.

A.C. Bovik. Ed.2. *The essential guide to image processing*. Academic Press, 2009.

A.M. Cormack. *Early two-dimensional reconstruction (CT scanning) and recent topics stemming from it*. Journal of Computer Assisted Tomography, v. 4, n. 5, p. 658–664, 1980.

B. Geiger. *Three-dimensional modeling of human organs and its application to diagnosis and surgical planning*. Research Report, RR-2105, INRIA. 1993. Inria-00074567.

Blender 2.83 Manual. *Triangles to Quads*. Disponível em: https://docs.blender.org/manual/fr/dev/modeling/meshes/editing/face/triangles_quads.html. Acessado em 1 de junho de 2020.

Blender Foundation. Disponível em <https://www.blender.org/>. Acessado em 1 de junho de 2020.

D. Mason. *SU-E-T-33: Pydicom: An Open Source DICOM Library*. Med. Phys., 38: 3493-3493. 2011. doi:10.1118/1.3611983

D. Wu, M. Sofka, N. Birkbeck, S.K. Zhou. 2014. *Segmentation of Multiple Knee Bones from CT for Orthopedic Knee Surgery Planning*. In: Golland P., Hata N., Barillot C., Hornegger J., Howe R. (eds) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2014. Lecture Notes in Computer Science, vol 8673. Springer, Cham, doi: 10.1007/978-3-319-10404-1_47

E.R. Dougherty and R.A. Lotufo. *Hands-on morphological image processing*. SPIE press, 2003.

F. Perez and B.E. Granger. *Project Jupyter: Computational narratives as the engine of collaborative data science*. Retrieved September, v. 11, n. 207, p. 108, 2015.

- G.N. Hounsfield. *Computerized transverse axial scanning (tomography): Part 1. Description of system*. The British journal of radiology, v. 46, n. 552, p. 1016-1022, 1973.
- H. Anton e C. Rorres. *Álgebra linear com aplicações*. Vol. 8. Porto Alegre: Bookman, 2001.
- H. Xie and L. Hou U (Ed.). *Web and Big Data*. APWeb-WAIM 2018 International Workshops: MWDA, BAH, KGMA, DMMOOC, DS, Macau, China, July 23–25, 2018, Revised Selected Papers. Springer, 2018.
- I. Idram, J.Y. Lai, T. Essomba and P.Y. Lee. 2017. *Study on Repositioning of Comminuted Fractured Bones for Computer-Aided Preoperative Planning*. In Proceedings of the 2017 4th International Conference on Biomedical and Bioinformatics Engineering (ICBBE 2017). Association for Computing Machinery, New York, NY, USA, 30–34. Doi: <https://doi.org/10.1145/3168776.3168801>
- Instituto Nacional de Traumatologia e Ortopedia (INTO). Ministério da Saúde do Brasil. Disponível em: <<https://www.into.saude.gov.br/>> Acessado em: 04 de janeiro de 2020.
- J. Coronel, J. Palacio e R. Rueda-Esteban. *Multiple software based 3D modeling protocol for printing anatomical structures*. Int. J. Morphol., 35(2): 425-429, 2017.
- J. Gomes e L. Velho. *Computação gráfica: imagem*. IMPA, 2002.
- J.P. Goldblatt and J.C. Richmond. 2003. *Anatomy and biomechanics of the knee. Operative Techniques in Sports Medicine*. Doi: 10.1053/otsm.2003.35911
- J.R. Haaga, C.F. Lanzieri, D.J. Sartoris e E.A. Zerhouni. *Tomografia Computadorizada e Ressonância Magnética do corpo humano*. 3 ed. Rio de Janeiro, RJ: Guanabara Koogan, c1996.
- J.W. Rohen, C. Yokochi, E. Lütjen-Drecoll and L.J. Romrell. 1998. *Color atlas of anatomy: A photographic study of the human body*. Stuttgart: Schattauer.
- M. Pinheiro and J.L. Alves. *A New Level-Set-Based Protocol for Accurate Bone Segmentation From CT Imaging*. in IEEE Access, vol. 3, pp. 1894-1906, 2015. Doi: 10.1109/ACCESS.2015.2484259.

M. Sonka, V. Hlava and R. Boyle. *Image processing, analysis, and machine vision*. Cengage Learning, 2014.

M. van Eijnatten, R. van Dijk, J. Dobbe, G. Streekstra, J. Koivisto and J. Wolff. *CT image segmentation methods for bone used in medical additive manufacturing*. *Medical engineering & physics*, v. 51, p. 6-16, 2018.

M. Vukicevic, D.S. Puperi, K.J. Grande-Allen and S.H. Little. *3D Printed Modeling of the Mitral Valve for Catheter-Based Structural Interventions*. *Ann Biomed Eng* (2016) 44: 3432, doi: 10.1007/s10439-016-1690-7

M.D. Harris, A.J. Cyr, A.A. Ali, C.K. Fitzpatrick, P. Rullkoetter, L. Maletsky and K.B. Shelburne. *A combined experimental and computational approach to subjects-specific analysis of knee joint laxity*. *J Biomech Eng*. 2016. 138(8). doi: 10.1115/1.4033882

M.J. Black, G. Sapiro, D.H. Marimont and D. Heeger. *Robust anisotropic diffusion*. *IEEE Transactions on image processing*, v. 7, n. 3, p. 421-432, 1998.

Natural Knee Data. University of Denver, Colorado, USA. Disponível em http://digitalcommons.du.edu/natural_knee_data. Acessado em 1 de junho de 2020.

Numpy-stl. Disponível em <https://pypi.org/project/numpy-stl/>. Acessado em 5 de janeiro de 2020.

O. Maier. *MedPy*. Disponível em <<https://pypi.python.org/pypi/MedPy>> Acessado em 05 de janeiro de 2020.

P. Marquez-Neila, L. Baumela and L. Alvarez. *A morphological approach to curvature-based evolution of curves and surfaces*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 36, n. 1, p. 2-17, 2013.

P. Mildenerger, M. Eichelberg and E. Martin. *Introduction to the DICOM standard*. *Eur Radiol* 12, 920–927. 2002. doi:10.1007/s003300101100

P. Perona and J. Malik. *Scale-space and edge detection using anisotropic diffusion*. *IEEE Transactions on pattern analysis and machine intelligence*, v. 12, n. 7, p. 629-639, 1990.

P.G. McMEnamin, M.R. Quayle, C.R. McHenry and J.W. Adams. (2014). *The production of anatomical teaching resources using three-dimensional (3D) printing technology*. American Association of Anatomists, 7: 479-486. doi:10.1002/ase.1475

P.H. Amorim, T.F. de Moraes, F.D.S. Azevedo e J.V. da Silva. 2011. *InVesalius: Software livre de imagens médicas*. Centro de Tecnologia da Informação Renato Archer-CTI, campinas/SP–2011-CSBC2011.

P.M. Trusty, T.C. Slesnick, Z.A. Wei, J. Rossignac, K.R. Kanter, M.A. Fogel and A.P. Yoganathan. *Fontan Surgical Planning: Previous Accomplishments, Current Challenges, and Future Directions*. J. of Cardiovasc. Trans. Res. 11, 133–144 (2018). Doi: 10.1007/s12265-018-9786-0

R. C. Gonzalez and R.E. Woods. 2006. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., USA.

R. Chityala and S. Pudipeddi. *Image processing and acquisition using Python*. Chapman and Hall/CRC. 2014.

S. Bassi. *Python for bioinformatics*. Chapman and Hall/CRC, 2017.

S. McKinley and M. Levine. 1998. *Cubic spline interpolation*. College of the Redwoods, 45(1), 1049-1060.

S. van der Walt, J.L. Schönberger, J. Nunez-Iglesias, F. Boulogne, J.D. Warner, N. Yager, E. Gouillart and T. Yu. The scikit-image contributors. 2014. *scikit-image: image processing in Python*. PeerJ 2:e453. Doi: 10.7717/peerj.453

T. Lewiner, H. Lopes, A.W. Vieira and G. Tavares. (2003). *Efficient implementation of marching cubes' cases with topological guarantees*. Journal of graphics tools, 8(2), 1-15.

T. Oliphant. 2007. *Python for Scientific Computing*. Computing in Science & Engineering. 9. 10-20. 10.1109/MCSE.2007.58.

T.F. Chan and L.A. Vese. *Active contours without edges*. IEEE Transactions on image processing, v. 10, n. 2, p. 266-277, 2001.

T.S. Yoo. *Insight into images: principles and practice for segmentation, registration, and image analysis*. AK Peters/CRC Press, 2004.

V. van Gogh. *Self Portrait*. 1889. Paintings, Drawings, Quotes and Biography. Disponível em: <https://www.vincentvangogh.org/self-portrait.jsp>. Acessado em 12 de março de 2020.

W.E. Lorensen and H.E. Cline. *Marching cubes: A high resolution 3D surface construction algorithm*. ACM siggraph computer graphics, v. 21, n. 4, p. 163-169, 1987.

W.R. Hendee and E.R. Ritenour. *Medical Imaging Physics*. 4 ed. Wiley-Liss, Inc., New York. c2002.