

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ

FABIANO UTIYAMA

SEGMENTAÇÃO EM ULTRA-ALTA DEFINIÇÃO DOS SISTEMAS DO CORPO
HUMANO DA BASE VHD USANDO TÉCNICAS DE REGISTRO DE IMAGENS

CURITIBA

2019

FABIANO UTIYAMA

SEGMENTAÇÃO EM ULTRA-ALTA DEFINIÇÃO DOS SISTEMAS DO CORPO
HUMANO DA BASE VHD USANDO TÉCNICAS DE REGISTRO DE IMAGENS

Tese apresentada ao Programa de Pós-Graduação em
Informática da Pontifícia Universidade Católica do
Paraná como requisito à obtenção do título de Doutor
em Informática.

Orientador: Prof. Dr. Edson José Rodrigues Justino

Coorientador: Prof. Dr. Flávio Bortolozzi

CURITIBA

2019

Dedico esta tese a Deus, minha inspiração e melhor amigo.

A meus pais Cláudio Irineu Utiyama e Miriam Aparecida de Assis Utiyama (*in memoriam*), as pessoas que mais investiram e acreditaram em mim.

À minha esposa Raquel Diniz Figueiredo Utiyama e meus filhos Giovana Diniz Utiyama e Pedro Henrique Diniz Utiyama, pela paciência e incentivo durante a elaboração do trabalho.

Também dedico ao meu “mestre” e orientador Prof. Dr. Edson José Rodrigues Justino, por sua competência e atenção.

Por fim, dedico ao meu coorientador, Prof. Dr. Flávio Bortolozzi, por me ensinar não somente a arte de escrever, mas por ser um nobre educador e um profissional exemplar.

DEDICATÓRIA

A Deus pela vida, paz, alegria, provisão e esperança.

Ao professor Dr. Edson José Rodrigues Justino, pela orientação, apoio, incentivos, confiança e principalmente pela amizade.

Ao professor Dr. Flávio Bortolozzi, pela confiança, acolhida e incentivo para o término deste trabalho.

Aos amigos e colegas de estudos William John Pereira Brobouski, Andrei Rafael Brongel, Mozart Gonçalves e Márcia Cristina Dadalto Pascutti, pela amizade, companheirismo e pela colaboração na realização deste trabalho.

Aos amigos e colegas de trabalho do eixo de informação e comunicação do IFPR, câmpus Paranavaí, por todo o apoio.

Aos meus irmãos e amigos da Igreja Batista da Lagoinha, pelas orações e incentivos.

Ao IFPR, pelo afastamento concedido no período de estudos.

À Capes, pelo auxílio financeiro.

RESUMO

O estudo da anatomia humana é exigido em quase todos os cursos relacionados às ciências da vida, aqueles relacionados à saúde, como medicina, enfermagem, fisioterapia, odontologia e outros. Atualmente, não há réplica, livro ou ferramenta computacional 3D que substitua o estudo a partir do corpo humano real. Existe também a dificuldade das universidades na aquisição de cadáveres para o estudo anatômico, e a degradação dos corpos existentes devido à sua manipulação por partes dos estudantes e profissionais. Percebeu-se, então, a necessidade do desenvolvimento de uma ferramenta de aprendizagem que atendesse às necessidades do estudo anatômico em laboratório, que fosse capaz de fazer a dissecação dos órgãos para o estudo da anatomia humana. Este trabalho foi inserido neste contexto, e tem como objetivo realizar a segmentação de imagens dos sistemas esquelético, circulatório, digestório, nervoso e respiratório do corpo humano, em ultra-alta definição, 2K, do corpo masculino da base de dados do Visible Human Database (VHD), usando como modelos de referência imagens em baixa definição (imagens de tomografia computadorizada ou de ressonância magnética), utilizando técnicas de registro de imagens, gerando modelos volumétricos com acuidade visual. Os resultados demonstram que o uso da abordagem utilizada possibilitou a segmentação dos sistemas do corpo humano propostos.

Palavras-Chave: segmentação de imagens, registro de imagens, imagens coloridas, ultra-alta definição, *visible human database*.

ABSTRACT

The study of human anatomy is required in almost all courses related to life sciences, those related to health, such as medicine, nursing, physiotherapy, dentistry and others. There is currently no 3D replica, book, or computational tool to replace study from the real human body. There is also the difficulty of universities in acquiring corpses for anatomical study, and the degradation of existing bodies due to their manipulation by students and professionals. It was then realized the need to develop a learning tool that would meet the needs of anatomical study in the laboratory, which could dissect the organs for the study of human anatomy. This work was inserted in this context, and aims to perform the image segmentation of the skeletal, circulatory, digestive, nervous and respiratory systems of the human body, in ultra-high definition, 2K, of the male body of the Visible Human Database (VHD), using as reference models low definition images (computed tomography or magnetic resonance images), using image recording techniques, generating volumetric models with visual acuity. The results demonstrate that the use of the approach used allowed the segmentation of the proposed human body systems.

Keywords: image segmentation, image registration, color images, ultra-high definition, visible human database.

LISTA DE FIGURAS

FIGURA 2.1: IMAGENS DE TC E RM.....	23
FIGURA 2.2: PASSOS QUE ENVOLVEM O REGISTRO DE IMAGENS.....	28
FIGURA 2.3: FOURIER E WAVELETS	35
FIGURA 2.4: LITOGRAFIAS A CORES DE UM CADÁVER CONGELADO CONTENDO O ÚTERO E O FETO (58 X 39 CM) DO ARTISTA C. SCHMIEDEL. ATLAS FOLIO DE WILHELM BRAUNE, PUBLICADO SIMULTANEAMENTE EM INGLÊS E ALEMÃO. CORTESIA DA BIBLIOTECA NACIONAL DE MEDICINA.	39
FIGURA 2.5: FOTOGRAFIA DE 70MM DE UMA FATIA (PLANO AXIAL) DE 0,33MM DE ESPESSURA DO CORPO CRIOGENADO.....	41
FIGURA 2.6: RECONSTRUÇÃO DA SEÇÃO FRONTAL DO HOMEM (ESQUERDA) E DA MULHER (DIREITA) MOSTRADA NA MESMA ESCALA	42
FIGURA 2.7: IMAGENS AXIAIS EM ULTRA-ALTA DEFINIÇÃO DO CADÁVER MASCULINO	43
FIGURA 2.8: SEGMENTAÇÃO DOS ÓRGÃOS DO CORPO HUMANO DA BASE SIO	45
FIGURA 2.9: IMPORTÂNCIA DA IDENTIFICAÇÃO DOS MÚSCULOS PARA A MARCAÇÃO DOS PONTOS.....	48
FIGURA 2.10: RESULTADO DO MÉTODO PROPOSTO NO ARTIGO.....	50
FIGURA 2.11: SEGMENTAÇÃO DA MEDULA ESPINHAL	51
FIGURA 3.1: FLUXOGRAMA DA ABORDAGEM PROPOSTA	56
FIGURA 3.2: DUAS IMAGENS, DE ÓRGÃOS DIFERENTES, COM INFORMAÇÕES DE UM MESMO CORTE	60
FIGURA 3.3: IMAGEM COM AS INFORMAÇÕES FUNDIDAS.....	60
FIGURA 3.4: ALGORITMO PARA FUSÃO DAS INFORMAÇÕES DE UM MESMO CORTE	60
FIGURA 3.5: SELEÇÃO DOS PONTOS COINCIDENTES ENTRE A BASE SIO E A VHD	62
FIGURA 3.6: QUANTIDADE DE SELEÇÃO DE PONTOS EM RELAÇÃO AO RESULTADO DO REGISTRO	63
FIGURA 3.7: ALGORITMO PARA O REGISTRO DE IMAGENS	63
FIGURA 3.8: ALGORITMO PARA APLICAÇÃO DO REGISTRO DE IMAGENS	64
FIGURA 3.9: ALGORITMO PARA CORREÇÃO NA RESOLUÇÃO	64
FIGURA 3.10: CORREÇÃO E AJUSTE NO REGISTRO ENTRE AS BASES	65
FIGURA 3.11: BINARIZAÇÃO DAS IMAGENS DA BASE SIO PARA A GERAÇÃO DA MÁSCARA ...	66
FIGURA 3.12: ALGORITMO PARA BINARIZAÇÃO DAS IMAGENS	66
FIGURA 3.13: APLICAÇÃO DA MÁSCARA À BASE VHD.....	67
FIGURA 3.14: ALGORITMO PARA APLICAÇÃO DA MÁSCARA	67

FIGURA 3.15: ALGORITMO PARA APLICAÇÃO DO FUNDO TRANSPARENTE	68
FIGURA 3.16: SISTEMA SEGMENTADO EM ULTRA-ALTA DEFINIÇÃO	69
FIGURA 4.1: DESAFIO DA PESQUISA – SEGMENTAÇÃO DO SISTEMA ESQUELÉTICO	74
FIGURA 4.2: SEGMENTAÇÃO DO SISTEMA ESQUELÉTICO	75
FIGURA 4.3: COMPARAÇÃO ENTRE O MÉTODO PROPOSTO E UMA IMAGEM SEGMENTADA DA UNIVERSIDADE DE HAMBURGO	76
FIGURA 4.4: REGISTRO AUTOMÁTICO COM O ALGORITMO SURF	78
FIGURA 4.5: DUAS IMAGENS, DE ÓRGÃOS DIFERENTES DO SISTEMA ESQUELÉTICO, COM INFORMAÇÕES DE UM MESMO CORTE	80
FIGURA 4.6: IMAGEM COM AS INFORMAÇÕES FUNDIDAS	80
FIGURA 4.7: SISTEMA ESQUELÉTICO EM ULTRA-ALTA DEFINIÇÃO	82
FIGURA 4.8: COMPARAÇÃO ENTRE O MÉTODO PROPOSTO E UMA IMAGEM SEGMENTADA MANUALMENTE	82
FIGURA 4.9: COMPARAÇÃO ENTRE O MÉTODO PROPOSTO E UMA IMAGEM SEGMENTADA MANUALMENTE (COM ZOOM)	83
FIGURA 4.10: DIFERENÇA DOS PERCENTUAIS DE SENSIBILIDADE, ESPECIFICIDADE E ACURÁCIA	84
FIGURA 4.11: COMPARAÇÃO ENTRE O MÉTODO PROPOSTO E UMA IMAGEM SEGMENTADA DA UNIVERSIDADE DE HAMBURGO	85
FIGURA 4.12: COMPARAÇÃO ENTRE O MÉTODO PROPOSTO E UMA IMAGEM SEGMENTADA POR HAMBURGO (COM ZOOM)	86
FIGURA 4.13: COMPARAÇÃO DOS RESULTADOS DAS IMAGENS DA BASE SIO COM AS IMAGENS GERADAS A PARTIR DA PROPOSTA DESTA PESQUISA, ATRAVÉS DA MÉTRICA DE SIMILARIDADE ESTRUTURAL	87
FIGURA 4.14: SISTEMA CIRCULATORIO SEGMENTADO	88
FIGURA 4.15: SISTEMA DIGESTÓRIO SEGMENTADO	89
FIGURA 4.16: SISTEMA NERVOSO SEGMENTADO	89
FIGURA 4.17: SISTEMA RESPIRATÓRIO SEGMENTADO	90
FIGURA 4.18: SISTEMA CIRCULATORIO SEGMENTADO COM A ABORDAGEM PROPOSTA E DA BASE SIO	90
FIGURA 4.19: SISTEMA DIGESTÓRIO SEGMENTADO COM A ABORDAGEM PROPOSTA E DA BASE SIO	91
FIGURA 4.20: SISTEMA NERVOSO SEGMENTADO COM A ABORDAGEM PROPOSTA E DA BASE SIO	92
FIGURA 4.21: SISTEMA RESPIRATÓRIO SEGMENTADO COM A ABORDAGEM PROPOSTA E DA BASE SIO	92
FIGURA 4.22: SISTEMA CIRCULATORIO SEGMENTADO COM A ABORDAGEM PROPOSTA E COM UMA SEGMENTAÇÃO MANUAL (<i>GROUND TRUTH</i>)	93

FIGURA 4.23: SISTEMA DIGESTÓRIO SEGMENTADO COM A ABORDAGEM PROPOSTA E COM UMA SEGMENTAÇÃO MANUAL (<i>GROUND TRUTH</i>)	94
FIGURA 4.24: SISTEMA NERVOSO SEGMENTADO COM A ABORDAGEM PROPOSTA E COM UMA SEGMENTAÇÃO MANUAL (<i>GROUND TRUTH</i>)	94
FIGURA 4.25: SISTEMA RESPIRATÓRIO SEGMENTADO COM A ABORDAGEM PROPOSTA E COM UMA SEGMENTAÇÃO MANUAL (<i>GROUND TRUTH</i>)	95
FIGURA 4.26: DIFERENÇA DOS PERCENTUAIS DE SENSIBILIDADE, ESPECIFICIDADE E ACURÁCIA	96
FIGURA 4.27: MESA DE DISSECAÇÃO EXIBINDO O SISTEMA ESQUELÉTICO SEGMENTADO PELA ABORDAGEM PROPOSTA NESTA PESQUISA	97

LISTA DE TABELAS

TABELA 4.1: RESULTADOS DO SEGUNDO EXPERIMENTO	83
TABELA 4.2: RESULTADOS DO SEGUNDO EXPERIMENTO – OUTRAS MÉTRICAS..	84
TABELA 4.3: RESULTADOS DO TERCEIRO EXPERIMENTO.....	86
TABELA 4.4: RESULTADOS DA SEGMENTAÇÃO COM A ABORDAGEM PROPOSTA NA PESQUISA EM RELAÇÃO AO <i>GROUND TRUTH</i>	95

LISTA DE QUADROS

Quadro 2.1: Técnicas utilizadas na literatura para realizar a segmentação de imagens médicas	27
Quadro 2.2: Metodologias de registro de imagens médicas.....	30
Quadro 2.3: Dados dos Cadáveres que Compõem a Base VHD	43
Quadro 2.4: Segmentação por órgãos da base SIO	46
Quadro 2.5: Bases pesquisadas.....	47
Quadro 2.6: Resumo das aplicações utilizando a base VHD	53
Quadro 3.1: Segmentação por órgãos e por sistema da base SIO	59
Quadro 3.2: Deslocamentos entre os cortes da base VHD.....	61
Quadro 3.3: Número do corte utilizado para o alinhamento para cada sistema.....	62
Quadro 3.4: Identificação dos órgãos do sistema esquelético.....	79

LISTA DE ABREVIATURAS

2D	Duas dimensões
3D	Três dimensões
A	Teste de Acurácia
CCD	Charge Coupled Device
CMOS	Complementary Metal-Oxide Semiconductor
CVH	Chinese Visible Human
D	Coeficiente de Similaridade Dice
DICOM	<i>Digital Imaging and Communication in Medicine</i>
DWT	<i>Discret Wavelet Transform</i>
E	Teste de Especificidade
J	Coeficiente de Similaridade Jaccard
MSE	<i>Mean Square Error</i>
PSNR	<i>Peak Signal-to-Noise Ratio</i>
RGB	Sistemas de cores (Red, Green e Blue)
RM	Ressonância Magnética
S	Teste de Sensibilidade
SIO	The Segmented Inner Organs
SIFT	Scale-Invariant Feature Transform
SSIM	Coeficiente de Similaridade Estrutural
SURF	Speeded-Up Robust Features
SVH	Shanghai Visible Human
TC	Tomografia Computadorizada
VHD	Visible Human Database

VKH Visible Korean Human

VTK The Visualization Toolkit

SUMÁRIO

1	INTRODUÇÃO	16
1.1	TEMÁTICA E PROBLEMATIZAÇÃO	16
1.2	OBJETIVOS.....	18
1.2.1	<i>Objetivo Geral</i>	18
1.2.3	<i>Objetivos Específicos</i>	18
1.3	JUSTIFICATIVA	19
1.4	MOTIVAÇÃO	19
1.5	CONTRIBUIÇÕES.....	20
1.6	ORGANIZAÇÃO DO TRABALHO	21
2	REVISÃO DA LITERATURA.....	23
2.1	IMAGENS DIGITAIS MÉDICAS	23
2.2	SEGMENTAÇÃO DE IMAGENS MÉDICAS	24
2.3	REGISTRO DE IMAGENS MÉDICAS	26
2.3.1	<i>Aplicações Clínicas de Registro de Imagens Médicas</i>	32
2.4	TÉCNICAS DE REGISTRO DE IMAGENS MÉDICAS	33
2.4.1	<i>Transformada Wavelet</i>	33
2.4.2	<i>SURF (Speeded-Up Robust Features)</i>	37
2.5	BASES DE DADOS DE IMAGENS MÉDICAS HUMANAS COLORIDAS.....	38
2.5.1	<i>The Visible Human Database</i>	40
2.5.2	<i>The Segmented Inner Organs</i>	44
2.6	REVISÃO DA LITERATURA SOBRE APLICAÇÕES UTILIZANDO A BASE VHD	46
2.6.1	<i>Segmentação dos Músculos para Representação 3D de Pontos para a Acupuntura</i>	48
2.6.2	<i>Segmentação, Reconstrução e Visualização da artéria pulmonar e da veia pulmonar de Imagens Anatômicas da VHD</i>	49
2.6.3	<i>Simulador Interativo de Dissecação de Cadáveres</i>	49
2.6.4	<i>Visualização e Segmentação do Sistema Cardíaco</i>	50
2.6.5	<i>Segmentação Automatizada da Medula Espinhal</i>	50
2.6.6	<i>Visualização do Coração a Partir de Imagens Seccionadas Utilizando uma Função de Transferência Híbrida</i>	51
2.6.7	<i>Segmentação e Reconstrução de Veias Hepáticas e Intra-Hepáticas Utilizando a Base Coronal VHD</i>	52
2.6.8	<i>Segmentação de Imagens Baseada em Rastreamento Adaptativo de Contornos Ativos Geométricos</i>	52

2.7	CONSIDERAÇÕES FINAIS	53
3	MATERIAIS E MÉTODOS	55
3.1	BASE DE DADOS DE IMAGENS COLORIDAS UTILIZADAS.....	57
3.2	FERRAMENTA COMPUTACIONAL UTILIZADA.....	57
3.3	ABORDAGEM PROPOSTA PARA A SEGMENTAÇÃO DOS SISTEMAS DO CORPO HUMANO EM ULTRA-ALTA DEFINIÇÃO	58
3.3.1	<i>Separação dos Sistemas do Corpo Humano da Base SIO.....</i>	<i>58</i>
3.3.2	<i>Fusão dos Cortes para a Formação da Base de Cada Sistema</i>	<i>58</i>
3.3.3	<i>Correção dos Deslocamentos entre Cortes da VHD</i>	<i>61</i>
3.3.4	<i>Registro da base de dados SIO com a base de dados VHD.....</i>	<i>61</i>
3.3.5	<i>Correção na Resolução entre as Bases</i>	<i>64</i>
3.3.6	<i>Binarização para a geração da máscara da base SIO.....</i>	<i>65</i>
3.3.7	<i>Aplicação da Máscara à Base de Dados VHD</i>	<i>66</i>
3.3.8	<i>Aplicação do Fundo Transparente às Imagens.....</i>	<i>68</i>
3.3.9	<i>Visualização do Sistema Segmentado.....</i>	<i>68</i>
3.4	VALIDAÇÃO DA ABORDAGEM PROPOSTA.....	68
3.4.1	<i>Mean Square Error (MSE).....</i>	<i>69</i>
3.4.2	<i>Peak Signal to Noise Ratio (PSNR).....</i>	<i>69</i>
3.4.3	<i>Similaridade Estrutural (SSIM).....</i>	<i>70</i>
3.4.4	<i>Coeficiente de Similaridade Jaccard (J).....</i>	<i>70</i>
3.4.5	<i>Coeficiente de Similaridade Dice (D)</i>	<i>71</i>
3.4.6	<i>Teste de Sensibilidade (S)</i>	<i>71</i>
3.4.7	<i>Teste de Especificidade (E)</i>	<i>71</i>
3.4.8	<i>Teste de Acurácia (A).....</i>	<i>72</i>
3.5	CONSIDERAÇÕES FINAIS	72
4	EXPERIMENTOS E RESULTADOS OBTIDOS	73
4.1	ANÁLISE DO MÉTODO DE SEGMENTAÇÃO	73
4.2	PROBLEMAS NA SEGMENTAÇÃO EM ULTRA-ALTA DEFINIÇÃO	76
4.3	EXPERIMENTOS REALIZADOS E ANÁLISE DOS RESULTADOS	77
4.3.1	<i>Primeiro Experimento.....</i>	<i>77</i>
4.3.2	<i>Segundo Experimento.....</i>	<i>78</i>
4.3.3	<i>Terceiro Experimento</i>	<i>85</i>
4.4	EXPERIMENTOS E ANÁLISE DE RESULTADOS COM OUTROS SISTEMAS DO CORPO HUMANO	88
4.5	APLICAÇÃO DA PESQUISA À UMA FERRAMENTA PARA O ESTUDO ANATÔMICO	96
4.6	CONSIDERAÇÕES FINAIS	97
5	CONCLUSÕES.....	99

CAPÍTULO 1

1 INTRODUÇÃO

Este Capítulo aborda a temática e a problematização, os objetivos gerais e específicos, a justificativa, a motivação e as contribuições do trabalho e faz uma exposição da organização da tese.

1.1 TEMÁTICA E PROBLEMATIZAÇÃO

O desenvolvimento tecnológico tem permitido muitos avanços no processamento digital de imagens, o que tem possibilitado inovar ou aprimorar soluções de problemas nas mais variadas áreas. No que se refere à área da saúde, projetos são desenvolvidos para a geração de recursos que atendam tanto aos profissionais, quanto aos estudantes em formação. A aquisição e o processamento de imagens permitem buscar ambientes computacionais que favoreçam o treinamento médico e o ensino de áreas como a anatomia, auxiliando no diagnóstico e no tratamento de doenças (BEVERIDGE et al., 2013).

O estudo da anatomia humana é exigido em quase todos os cursos relacionados às ciências da vida, aqueles relacionados à saúde, como medicina, enfermagem, fisioterapia, odontologia e outros. Atualmente, não há réplica, livro ou ferramenta computacional 3D que substitua o estudo a partir do corpo humano real. Algumas características como cor, profundidade, textura e posição anatômica são essenciais para uma aprendizagem abrangente. O cadáver é o mais próximo que o aluno pode ter de um ser humano vivo, mesmo que algumas

propriedades do corpo do ser humano não possam ser observadas em tecidos mortos, como atividade cerebral, vascularização, batimentos cardíacos, entre outros.

Segundo a Sociedade Brasileira de Anatomia (SBA) (LIMA, 2014), as Faculdades e Universidades estão enfrentando dificuldades em obter corpos para estudos de anatomia. As principais razões, segundo a mesma fonte, são devidas ao aumento exponencial das Faculdades e Universidades, pela redução gradual de cadáveres não reclamados, a falta de informação sobre a possibilidade de doações de cadáveres (BASSETTE, 2014), bem como os procedimentos burocráticos e legais envolvidos.

O tempo pequeno de vida útil dos corpos é outro problema em relação à manutenção dos laboratórios de anatomia, devido à degradação natural e a manipulação por parte dos usuários. Como resultado, o que acontece hoje em laboratórios de anatomia é a falta de corpos e partes anatômicas em condições para serem utilizadas na aprendizagem. Esta realidade prejudica a assimilação do conteúdo por parte dos estudantes, comprometendo o conhecimento necessário para a sua formação.

Uma possível solução é a visualização digital destas informações, porém, dada a complexidade das estruturas orgânicas, o processo de visualização digital em alta definição e a segmentação dos órgãos e sistemas do corpo humano é uma tarefa complexa e exige alta capacidade computacional. Sob o ponto de vista anatômico, a divisão ou separação em sistemas se faz necessário, para a perfeita compreensão de suas partes.

Na área da saúde é importante também que as ferramentas computacionais exibam modelos realistas do corpo humano. Existem no mercado ferramentas de anatomia que permitem a dissecação humana, porém geram artefatos sintéticos do corpo, não expressando a cor e a textura real.

Um exemplo de ferramenta, é o projeto conhecido como *The Voxel-Man*, que utiliza uma base de dados desenvolvida pela Universidade de Hamburgo, em baixa resolução, conhecida como *The Segmented Inner Organs (SIO)*. Esta base de dados de imagens é

sintética, produzida através de edição e correções computacionais, gerada a partir da base Visible Human Database (VHD).

Imagens sintéticas geram alguns problemas para o estudo anatômico, como a redução da qualidade na representação, ocasionados por correções manuais que não representam as estruturas orgânicas realistas.

Observou-se, diante deste cenário, a necessidade de desenvolvimento de uma ferramenta de aprendizagem que atendesse às necessidades do estudo anatômico em laboratório através da visualização de artefatos em alta resolução e com cores e texturas realistas, realizando procedimentos como a dissecação do cadáver, necessário para auxiliar os estudantes em seu processo de aprendizagem.

1.2 OBJETIVOS

1.2.1 *Objetivo Geral*

Realizar a segmentação de imagens dos sistemas do corpo humano em ultra-alta definição, 2K, do corpo masculino da base VHD, usando como modelos de referência imagens em baixa definição (imagens de tomografia computadorizada ou de ressonância magnética), utilizando técnicas de registro de imagens, gerando modelos volumétricos com acuidade visual. Os sistemas segmentados serão o esquelético, circulatório, digestório, nervoso e respiratório, podendo o método utilizado ser aplicado a outros.

1.2.3 *Objetivos Específicos*

Os objetivos específicos da pesquisa são:

- fazer uma pesquisa sobre a segmentação de imagens utilizando a base VHD;
- descrever a base SIO e processo de segmentação utilizado para a obtenção dos modelos em baixa definição;

- revisar os métodos de registro de imagens coloridas e em ultra-alta definição;
- desenvolver uma abordagem para a segmentação dos sistemas do corpo humano, para a geração de modelos com acuidade visual; e
- avaliar o desempenho da abordagem proposta utilizando métricas computacionais.

1.3 JUSTIFICATIVA

Justifica-se por prover um ambiente computacional que represente os órgãos e sistemas do corpo humano de forma real, em relação às cores e texturas, em um ambiente volumétrico com acuidade visual. A estrutura cerebral, por exemplo, apresenta características de profundidade e detalhes estruturais difíceis de serem observadas em um projetor (monitor, por exemplo) bidimensional (2D), como o apresentado por algumas ferramentas disponíveis no mercado. Para esses casos, são necessários imagens de ultra-alta definição (2k ou superior) e representação estrutural em profundidade, sendo possível ser exibida com a tecnologia atual de fotografia associada à estereoscopia.

Assim sendo, este projeto busca atender às necessidades na obtenção de ferramentas de ensino de anatomia, que complementem o estudo de peças anatômicas em laboratório (sistemas do corpo humano), atendendo principalmente aos estudos iniciais da anatomia, tendo como características predominantes o custo viável e acuidade visual.

1.4 MOTIVAÇÃO

A área tecnológica tem auxiliado a medicina na resolução de vários problemas pontuais, tais como exames e diagnósticos por imagens, cirurgias auxiliadas por computadores, e em especial, o ensino da anatomia humana.

O cadáver é o modelo mais próximo que os estudantes têm de um ser humano vivo, porém algumas propriedades como cor e textura não podem ser observadas de forma realista

em tecidos mortos. Além disso, existe a dificuldade das instituições de ensino em adquirir cadáveres principalmente por questões burocráticas e legais envolvidas. Soma-se a isso o tempo de vida útil pequeno e a degradação do corpo devido à manipulação por parte dos estudantes e profissionais da área de saúde.

A dissecação dos órgãos e sistemas se faz necessário para a perfeita compreensão de suas partes dada a complexidade do corpo humano. Existem no mercado ferramentas que permitem a visualização e separação dos órgãos humanos, porém geram elementos sintéticos, não expressando a cor e a textura real. Também não possibilitam a visualização das estruturas realistas do corpo humano em ultra-alta definição.

A principal motivação para a realização deste trabalho é a segmentação dos sistemas esquelético, circulatório, digestório, nervoso e respiratório do corpo humano, gerando modelos volumétricos com acuidade visual, capaz de distinguir detalhes espaciais, contornos e formas dos objetos, baseado no registro de imagens médicas coloridas em 2K, para o estudo da anatomia humana. A finalidade é proporcionar um ambiente de fácil compreensão para estudantes de anatomia, bem como reproduzir corpos humanos em alta resolução, com cores e texturas realistas.

1.5 CONTRIBUIÇÕES

Este estudo obteve as seguintes contribuições:

- estudo da base de dados VHD, mostrando aplicações na área de segmentação de imagens;
- nova abordagem para a segmentação dos sistemas do corpo humano, através de imagens coloridas em 2k, utilizando o registro de imagens, gerando um modelo volumétrico com acuidade visual; e
- estudo e a análise da abordagem proposta, mostrando sua eficácia na realização da segmentação dos sistemas do corpo humano.

1.6 ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado em quatro capítulos da seguinte forma: O primeiro Capítulo apresenta a introdução, comentando a temática e a problematização, os objetivos gerais e específicos, a justificativa, a motivação as contribuições da pesquisa. O segundo Capítulo aborda a fundamentação teórica e o estado da arte das bases VHD e SIO, segmentação de imagens em ultra-alta definição e registro de imagens médicas. O terceiro Capítulo apresenta as etapas que envolvem a abordagem proposta, as bases de dados utilizadas e os critérios usados na validação da abordagem. O quarto Capítulo expõe os resultados obtidos. O quinto Capítulo relata as conclusões finais. Por fim, encontram-se as referências bibliográficas utilizadas.

CAPÍTULO 2

2 REVISÃO DA LITERATURA

Este Capítulo aborda o conceito de imagens digitais médicas e faz um estudo sobre a base de dados VHD e a base SIO. Apresenta também um estudo sobre a segmentação de imagens utilizando a base VHD e mostra técnicas para o registro de imagens médicas.

2.1 IMAGENS DIGITAIS MÉDICAS


O interesse por imagens digitais e seus métodos de processamento provém da melhora das informações visuais para a interpretação humana e processamento de dados e imagens para armazenamento, transmissão e representação, considerando a percepção automática por máquinas (GONZALEZ, 2008).

“Uma imagem pode ser definida como uma função bidimensional, $f(x, y)$ em que x e y são coordenadas espaciais (plano), e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto” (GONZALEZ, 2008). Quando os elementos x, y e os valores de intensidade de f são quantidades finitas e discretas, dá-se o nome de imagem digital.

As imagens digitais podem ser produzidas por diversos aparelhos, utilizando fontes diversas como os raios X, para gerar exames de radiografia e tomografia computadorizada (TC), e banda de rádio, para geração de exames como o de ressonância magnética (RM).

A Figura 2.1a exibe uma imagem de TC e a Figura 2.2 mostra uma imagem de RM.

Figura 2.1: Imagens de TC e RM



Fonte: NATIONAL LIBRARY OF MEDICINE, 2019

Os raios X estão entre as fontes mais antigas de radiação utilizada para a formação de imagens. São utilizados principalmente no diagnóstico médico, mas eles também são utilizados na indústria e astronomia.

As principais aplicações de imagens obtidas por banda de rádio situam-se na medicina e na astronomia. Na medicina, são utilizadas em imagens por ressonância magnética. A RM pode produzir imagens em qualquer plano dos eixos cartesianos.

Com o intuito de padronizar as imagens geradas por aparelhos como os de RM e TC, foi desenvolvido o padrão *Digital Imaging and Communications in Medicine* (DICOM) que atualmente é utilizado na maioria dos equipamentos de produção de imagens médicas (SUETENS, 2017). É um protocolo para transferência, armazenamento e exibição de todos os aspectos funcionais de imagens médicas digitais (PIANYKH, 2009).

As imagens médicas coloridas em ultra-alta definição são obtidas a partir de câmeras digitais. Câmeras Digitais usam um dispositivo chamado *Charge Coupled Device* (CCD) que

atua como se fosse o filme fotográfico. Alcançam resoluções de 640x480 até milhares de pixels. Os *Line Scan* CCDs são usados para altas resoluções, com alta linearidade, alta banda dinâmica e *readout* lento e possuem qualidade muito boa. Mais recentemente surgiram algumas câmeras que utilizam *Complementary Metal-Oxide Semiconductor* (CMOS) como sensores. A grande vantagem é a viabilidade industrial pois utilizam a mesma tecnologia de semicondutores tradicionais para produção em baixo custo (SCURI, 1999).

O sistema de cor é o *Red, Green e Blue* (RGB). A calibração pode ser feita como um scanner, mas a qualidade da imagem depende de fatores externos, como a iluminação do objeto. Algumas câmeras utilizam 3 sensores para capturar a imagem, um para cada componente de cor R, G e B (SCRUI, 2002).

2.2 SEGMENTAÇÃO DE IMAGENS MÉDICAS

Facon (1996) e Huang (2006) afirmam que a segmentação de imagens é uma tarefa comum na área de processamento digital de imagens. É aplicada em múltiplas áreas, como na medicina, nas indústrias, em imagens de satélite, reconhecimento de padrões, visão computacional, entre outras (FACON, 1996; HUANG, 2006).

Segundo Facon (1996) o processo de segmentação consiste em subdividir a imagem em “unidades significantes” que podem ser regiões, bordas e texturas com atributos similares. Seu objetivo é simplificar ou alterar a representação de uma imagem, com a finalidade de facilitar sua análise, eliminando informações irrelevantes e preservando as que auxiliam na compreensão da imagem (FACON, 1996).

Até hoje não existe uma teoria única de segmentação de imagens, pelo contrário, existem múltiplas abordagens. Para realizar uma boa segmentação, Haralick (1985) e Wangenheim (1998) estabeleceram algumas diretrizes de qualidade, sendo:

- As “unidades significantes” de segmentação de uma imagem devem ser uniformes e homogêneas em relação a algumas características, tais como escala de cinza ou textura;
- As “unidades significantes” interiores devem ser simples e sem muitos pequenos orifícios;
- As “unidades significantes” adjacentes de uma segmentação devem ter valores significativamente diferentes no que diz respeito à característica em que eles são uniformes; e os limites de cada unidade significativa devem ser simples, não irregulares e devem ser espacialmente precisos.

Em geral, pode-se dividir as abordagens de segmentação em três categorias: por região; contorno ou textura.

A segmentação por regiões permite a classificação de uma imagem através de características espaciais, verificando se um determinado ponto pertence a uma região. “Uma região pode ser definida como sendo um conjunto de pontos que respeitam um mesmo predicado de homogeneidade. A escolha da propriedade de homogeneidade é com certeza o parâmetro decisivo para extrair boas regiões” (FACON, 2001).

A detecção de regiões numa imagem pode ser feita com dois objetivos, extrair uma determinada região; e dividir (particionar) a imagem num conjunto de regiões disjuntas cuja união representa a imagem inteira.

Existem algumas técnicas comumente utilizadas na segmentação por região, como crescimento de regiões (*Region Growing*), divisão e fusão (*Split and Merge*), limiarização (*Threshold*) e bacias hidrográficas (*Watershed*).

A segmentação por contorno segundo Pinheiro (2005) consiste em localizar pontos onde ocorram estas mudanças bruscas entre os níveis de cinza, permitindo assim a identificação dos objetos. Um contorno, ou borda, representa a fronteira entre duas regiões caracterizada pela mudança brusca do nível de cinza entre duas regiões relativamente

homogêneas. Ele pode aparecer como uma sequência de pontos, uma linha, um segmento, uma curva ou uma forte variação do nível de cinza médio.

Normalmente, as abordagens de segmentação por contorno seguem alguns passos como o cálculo das bordas de uma imagem contendo todos os contornos de uma imagem original. Em seguida processar os contornos da imagem de modo que apenas os objetos com limites fechados permaneçam, e por fim gerar a imagem segmentada. O problema muitas vezes está em transformar um contorno em uma imagem de limites fechados, pois em alguns casos, este processo requer a remoção de arestas que são causadas por ruídos ou outros artefatos.

A segmentação por textura permite a colocação em evidência dos motivos da imagem, considerando-se as propriedades de regularidade e de repetição de um padrão (TAMURA, 1978). A noção de textura supõe que o motivo seja um agrupamento aleatório ou não aleatório de subconjuntos da imagem; as entidades detectadas sejam uniformes e tenham aproximadamente as mesmas dimensões em qualquer lugar da imagem; e o motivo local seja repetido numa região comparativamente larga em relação ao tamanho desse motivo.

O Quadro 2.1 mostra algumas técnicas utilizadas na literatura para realizar a segmentação de imagens médicas (KAUR, 2017).

2.3 REGISTRO DE IMAGENS MÉDICAS

Registro de imagens médicas é o processo de sobreposição de duas ou mais imagens geradas por sensores iguais ou distintos, em momentos diferentes, alinhadas de forma que integre as informações e proporcione um documento mais preciso para o diagnóstico de diversas doenças, como tumores cerebrais, ou para o estudo anatômico (ZITOVÁ, 2003). Também pode ser definido como o processo de alinhamento de duas ou mais imagens (OLIVEIRA, 2014).

Quadro 2.1: Técnicas utilizadas na literatura para realizar a segmentação de imagens médicas

Autor/Ano	Publicação	Técnica	Objetivo
(KAUSHIK, 2013)	IJCA	Algoritmo genético	Breve ideia de várias metodologias de segmentação
(KUMAR, 2014)	IJCTA	Estudo do processamento de imagens médicas na área de cuidados da saúde	Estado do arte sobre processamento de imagens médicas
(SREEDEVI, 2016)	IJRS	Método da distância Minkowski	Algoritmo genético para diagnosticar diabetes
(PATIL, 2013)	IJCSMC	Técnica baseada na borda	Mostrar que o resultado da segmentação é afetado por muitos fatores
(AHIRWAR, 2013)	IJTC	Redes neurais	Melhorar a extração de dados
(SOVILJ-NIKIC, 2007)	PIMCSIT	Princípio da teoria evolucionária de Darwin	Implementar de forma recursiva e não recursiva, o filtro fuzzy mediano
(BHASIN, 2011)	IJCSIT	Algoritmo de aprendizagem por reforço	Analisar uma jogada em um xadrez
(RAJAEI, 2012)	ITCSCP	Ruído adaptativo 2D aplicado a remoção usando vizinhos	Remover ruídos e suavizar imagens
(LASHARI, 2013)	ICEEI	Algoritmo de mineração de dados e técnicas de visualização	Melhorar a precisão e velocidade computacional
(HUO, 2015)	IJSIPPR	Descontinuidade dos níveis de cinza	Modelo M-L proposto para a segmentação de imagens médicas
(ALY, 2011)	IJCSIT	Extração de informação de um conjunto de treinamento	Requisitos práticos para projetar algoritmos apropriados
(SAINI, 2014)	IJICT	Processo de inundação	Uma nova abordagem de segmentação
(RASTGARPOUR, 2011)	IMECS	Método de segmentação dependente da modalidade e dimensão	Avanço nas técnicas de IA utilizando machine learning
(KAUR, 2014)	IJCSMC	Deteção de borda baseado no valor de intensidade	Técnica de deteção de bordas baseada na localização das arestas

Fonte: KAUR, 2017

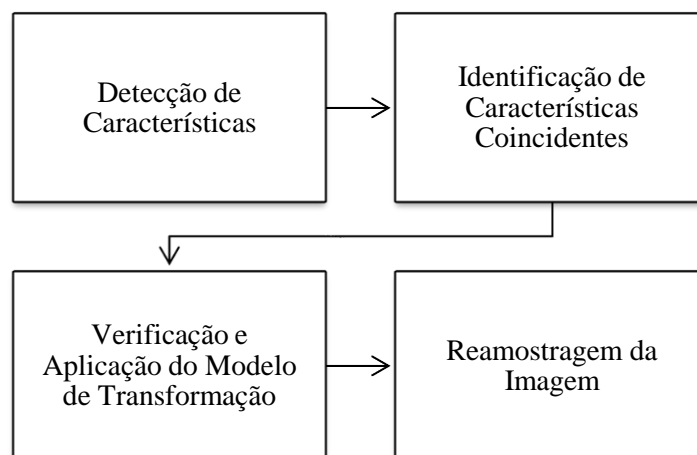
A sobreposição de imagens é feita através da deteção de pontos equivalentes entre as duas imagens, ou fatias proporcionais em elementos tridimensionais. O registro permite fazer o alinhamento e a justa sobreposição das imagens ou objetos tridimensionais.

O alinhamento das imagens permite gerar um documento com informações mais completas e precisas, auxiliando em diversos procedimentos de diagnósticos de doenças, acompanhamento de pacientes e permite melhorar a segmentação ou reconstrução de elementos tridimensionais para outros tipos de análises (TING, 2002).

De acordo com Wyawahare (2009), o registro de imagens envolve quatro passos (Figura 2.2):

- Detecção de características: regiões, bordas, contornos, interseções de linhas, cantos, e outras características são detectadas, de ambas as imagens;
- Identificação de características coincidentes: correspondência entre as características da imagem de referência e imagem detectada;
- Verificação e aplicação do modelo de transformação: tipo e parâmetros da função de mapeamento, alinhando a imagem detectada à imagem de referência;
- Reamostragem da imagem: a imagem é transformada por meio da função de mapeamento.

Figura 2.2: Passos que envolvem o registro de imagens



Fonte: WYAWAHARE, 2009

Diferentes métodos para realizar o alinhamento de imagens multimodais 2D/3D foram propostos nos últimos anos. Elsen, Pol e Viergever (1993) apresentam uma revisão desses métodos. Maintz e Viergever (1998) apresentam uma revisão bibliográfica de publicações envolvendo registro de imagens médicas. Hellier e Barillot (2003) também apresentam alguns desses métodos. Dalley (2001) compara vários algoritmos de registro para um mesmo conjunto de dados utilizando variantes de algoritmos comuns de registro. Likar e Pernus

(2001) apresentam uma classificação dividida em métodos baseados em segmentação, baseado em intensidade e híbrido. Hajnal, Hawkes e Hill (2001) apresentam uma série de artigos envolvendo metodologia, aplicação de registro rígido e técnicas e aplicações de registro não-rígido.

Elsen, Pol e Viergever (1993) classificaram os métodos de registro de imagens médicas pela dimensionalidade dos dados (2D, 3D, ...), a fonte dos recursos de imagem usados para fazer o registro (propriedades intrínsecas ou extrínsecas de pacientes), domínio de transformação (local ou global), a elasticidade de transformação (rígido, afim, projetiva ou curva), ajuste de propriedade de acoplamento (interpolação ou aproximação), determinação de parâmetros (direta ou por pesquisa orientada) e interação (interativo, semiautomático ou automático). Este sistema de classificação foi mais pormenorizado estendendo-se a nove critérios fundamentais por Maintz e Viergever (1998), e cada critério foi dividido em um ou mais subcritérios (Quadro 2.2).

Em relação às transformações geométricas, define-se como o mapeamento de pontos de um espaço X para o espaço Y . Uma transformação τ aplicada a um ponto em X , representado por um vetor de colunas x , produz um ponto x' transformado (Equação 2.1) (FITZPATRICK, 2016).

$$x' = \tau(x) \quad (2.1)$$

Se um ponto y em Y corresponde a x' , então um registro com sucesso (igual ou aproximadamente igual) foi realizado. As transformações geométricas podem ser divididas em rígidas e não rígidas, conforme descrito no Quadro 2.2.

Transformações rígidas, ou mapeamentos rígidos, são definidos como transformações geométricas que preservam todas as distâncias. Essas transformações também preservam a

retidão das linhas (planaridade das superfícies) e todos os ângulos diferentes de zero entre linhas retas.

Quadro 2.2: Metodologias de registro de imagens médicas

Critérios de Classificação	Subdivisões	
Dimensionalidade	Dimensões espaciais: 2D/2D, 2D/3D, 3D/3D	
Natureza da Base de Registro	Extrínseco (baseado em objetos secundários introduzidos na imagem)	
	Intrínseco (baseado na informação da imagem)	
	Não baseado na imagem (coordenadas da imagem de dois dispositivos são unidos)	
Natureza de Transformação	Rígida (somente translação e rotação)	
	Não rígida - Afim (translação, rotação, escala)	
	Não rígida – Projetiva	
	Não rígida – Perspectiva	
Domínio da Transformação	Local	
	Global	
Interação	Interativo	Inicialização fornecida
		Inicialização não fornecida
	Semiautomático	Inicialização pelo usuário
		Direção do usuário para correção
		Ambos
Automático		
Procedimento de Otimização	Parâmetros computados (os parâmetros de transformação são computados diretamente)	
	Parâmetros procurados (os parâmetros de transformação são computados usando algoritmos de otimização)	
Modalidades envolvidas no registro	Monomodal (CT/CT, MRI/MRI, PET/PET)	
	Multimodal (CT/MRI, CT/PET, CT/SPECT, PET/MRI, MRI/US)	
	Modalidade para o modelo	
	Paciente para a modalidade (alinhar o paciente com o sistema de coordenadas do ambiente)	
Assunto	Intersubjetivo	
	Intrasubjetivo	
	Atlas (base de dados de muitas imagens)	
Objeto	Cabeça (crânio, olhos)	
	Tórax (cardíaco, mama)	
	Abdômen (rim, fígado)	
	Membros	
	Vértebras	

Fonte: MAINTZ, 1998 e WYAWAHARE, 2009

Problemas de registro que estão limitados a transformações rígidas são chamados de problemas de registros rígidos. Existem vários métodos de registro rígido e em cada método há dois componentes que devem ser especificados, a translação e a rotação (FITZPATRICK, 2016).

A Equação 2.2 descreve de forma geral uma transformação rígida, sendo R o componente que descreve o ângulo de rotação e t a especificação das coordenadas x , y e z no plano cartesiano (FITZPATRICK, 2016).

$$x' = Rx + t \quad (2.2)$$

Transformações não rígidas são importantes não somente para aplicações de caráter não rígido, mas em situações em que há distorções não rígidas no procedimento de aquisição das imagens. Uma simples transformação não rígida pode ser descrita do mesmo modo que uma transformação rígida, incluindo o fator de escala (Equação 2.3) (FITZPATRICK, 2016).

$$x' = RSx + t \quad (2.3)$$

O S , portanto, representa os elementos do fator de escala ao longo dos três eixos de coordenadas. O R é o componente que descreve o ângulo de rotação e t a especificação das coordenadas x , y e z no plano cartesiano. x é a imagem de entrada e x' a imagem de saída. Um dos tipos de transformação não rígida, é a transformação afim, descrita pela Equação 2.4 (FITZPATRICK, 2016).

$$x' = Ax + t \quad (2.4)$$

t representa a especificação das coordenadas x , y e z no plano cartesiano. x é a imagem de entrada e x' a imagem de saída. A transformação afim (A) preserva a linearidade das linhas (planaridade das superfícies), mas permite que os ângulos entre as linhas sejam alterados. Outros tipos de transformações não rígidas incluem a transformação projetiva, perspectiva e curva (FITZPATRICK, 2016).

2.3.1 *Aplicações Clínicas de Registro de Imagens Médicas*

Uma das áreas da medicina que utilizam o registro de imagens é a neurologia. Estudo em exames de demência, esclerose múltipla, tumores do sistema nervoso central e epilepsia, são exemplos disto. Comparação de imagens registradas ao longo de um determinado tempo são muito úteis no diagnóstico da evolução destas doenças (BANKMAN, 2002).

O registro com a posterior subtração de imagens em série, contribui também com a avaliação de hemorragia no cérebro e perturbações de perfusão do sangue no tecido. Uma aplicação recente é a localização de epilepsia focal (um tipo de epilepsia com crises que começam em uma parte limitada do cérebro).

O registro de imagens de RM e TC de alta resolução fornecem uma base anatômica muito mais precisa para a interpretação dos dados de imagens funcionais. Isto permite a melhor detecção de distúrbios funcionais focais da atividade cerebral, melhor compreensão da estrutura fisiopatológica, maior precisão na identificação de padrões específicos de distúrbios em um grupo de pacientes. Também podem ajudar a detectar diagnósticos clínicos ambíguos, de lesões estruturais e outras anormalidades (BANKMAN, 2002).

A sobreposição de imagens de modalidades diferentes também auxilia na interpretação de imagens clínicas para a tomada de decisão em tratamentos de pacientes. Por exemplo, na avaliação de pacientes com tumores cerebrais, apenas com as imagens de RM o diagnóstico poderia ser enganoso devido a alteração de realces de contraste.

Localização da zona epileptogênica, região focal do cérebro responsável pela geração de convulsões, é o objetivo das avaliações pré-operatórias para cirurgia de epilepsia. Este processo tem sido realizado utilizando-se o registro de imagens multimodais.

Uma aplicação emergente é o registro de imagens envolvendo um grupo de pacientes. Registro interindividual permite a comparação de alterações patológicas entre uma população de pacientes de interesse. Pesquisas realizaram o mapeamento estatístico paramétrico para medir objetivamente a distribuição de benzodiazepina em cada paciente (BANKMAN, 2002).

Enfim, a análise de componentes e padronização anatômica utilizando o registro de imagens é um avanço na interpretação objetiva de imagens funcionais que tendem a ser cada vez mais comum em clínicas de diagnóstico por imagem.

2.4 TÉCNICAS DE REGISTRO DE IMAGENS MÉDICAS

As técnicas de registro implementadas e analisadas neste trabalho são apresentadas nesta seção.

2.4.1 *Transformada Wavelet*

Observando as imagens, geralmente vê-se regiões vinculadas por textura e níveis de intensidade similares, que se combinam para formar objetos. Se os objetos forem pequenos ou de baixo contraste, normalmente serão analisados em altas resoluções; se forem grandes ou de alto contraste, basta uma visão grosseira. Se objetos tanto pequenos quanto grandes – ou objetos de baixo e alto contraste – estiverem presentes simultaneamente, pode ser interessante analisá-los em várias resoluções. Essa é a motivação fundamental do processamento multiresolução (GONZALEZ, 2008).

Uma estrutura eficiente, porém, conceitualmente simples para representar as imagens em mais de uma resolução é a pirâmide de imagem. Originalmente elaborada para aplicações

de visão de máquina e compressão de imagens, uma pirâmide de imagem é uma coletânea de imagens de resolução cada vez menor, organizada no formato de uma pirâmide. A base da pirâmide contém uma representação de alta resolução da imagem sendo processada; o ápice contém uma aproximação de baixa resolução. À medida que se sobe na pirâmide, tanto o tamanho quanto a resolução diminuem (GONZALEZ, 2008).

Outra técnica importante na aquisição de imagens relacionada à análise multiresolução é a codificação em sub-bandas. Nela uma imagem é decomposta em um conjunto de componentes de banda limitada, chamados de sub-bandas. A decomposição é realizada de forma que as sub-bandas possam ser novamente montadas para reconstruir a imagem original sem erro (GONZALEZ, 2008).

As *wavelets* são ondas pequenas, com determinadas propriedades, que as tornam adequadas para decomposição de uma determinada função em outras funções. As funções do domínio *wavelet* podem ser aplicadas de forma específica ou se ajustarem conforme a necessidade do processamento, o que torna a transformada *wavelet* uma ferramenta versátil (MISITI, 1996).


De acordo com Rocha (2008), *wavelet* é definida como sendo uma forma de onda com duração limitada e um valor médio igual a zero. O comportamento de uma *wavelet* é comparável ao de uma senóide, que por sinal é a base da análise de séries de Fourier. Porém, embora as senóides apresentem comportamento tipicamente suave e previsível, as *wavelets* diferem pelo fato de se apresentarem de forma irregular e assimétrica.

Elas são geradas a partir de translações (b) no espaço e escalonamentos (dilatações ou contrações) (a) de uma única função $\psi(t)$ denominada *wavelet* mãe, representada na Equação 2.5 (OLIVEIRA, 2007).

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.5)$$

A multiresolução permite que as *wavelets* tenham certa flexibilidade na análise do sinal, podendo ser feita em frequências e resoluções diferentes. Desta forma é possível decompor e descrever outras funções em três dimensões (tempo, escala e intensidade de energia), distinguindo das séries de Fourier onde as funções são dependentes apenas da frequência (Figura 2.3).

Figura 2.3: Fourier e Wavelets



Fonte: TURMERO, 2019

A decomposição de uma função através de *wavelets* é chamada de transformada de *wavelet* e pode ser contínua ou discreta. Na computação, bem como na área de processamento digital de imagens, utiliza-se a transformada *wavelet* discreta, pela necessidade de representar as informações de maneira lógica, não-contínua. Para Rocha (2008), a transformada discreta de *wavelet* (DWT, do inglês *Discrete Wavelet Transform*) é a ferramenta mais utilizada para decomposição de sinais via *wavelets* envolvendo aplicações práticas.

A DWT consiste em dividir o sinal que está analisando em componentes de alta e baixa escala, sendo os componentes de alta escala denominados “aproximações” (conteúdos de baixa frequência) e os de baixa escala denominados “detalhes” (conteúdo de alta

frequência). Esse processo acaba gerando duas novas subséries a partir da série original e aparentemente aumenta a complexidade, porém a decomposição da DWT é feita reduzindo a taxa ou variação de amostragem proporcionalmente ao número de decomposições para evitar que a complexidade aumente (ROCHA, 2008).

A transformada *wavelet* discreta (d) é definida pela Equação 2.6, onde $n = 2^j$ (OLIVEIRA, 2007).

$$d_{j,k} = \sum_{t=0}^{n-1} x_t \psi_{j,k}(t) \quad (2.6)$$

Segundo Oliveira (2007), a transformada *wavelet* tem sido aplicada nas mais diversas áreas, disponibilizando algoritmos rápidos, fundamentais para compressão de imagens, ou para a remoção de ruído. A redução de ruído através das *wavelets* é conhecida por *denoising*.

O *denoising* por *wavelets* preservam a informação e consistência dos dados do sinal original através dos coeficientes determinados. O objetivo é remover os coeficientes que provocam ruídos na imagem. Por meio da função base e o número de níveis que se deseja decompor a série, as *wavelets* selecionam um número mínimo de coeficientes remanescentes, porém com alta concentração de energia – comparável à energia do sinal em seu estado original (ROCHA, 2008).

As *wavelets* também podem ser utilizadas no registro de imagens e foram implementadas e analisadas no registro de imagens em ultra-alta definição, mas observou-se que sua verdadeira aplicação está ligada à fusão de imagens médicas. Isto porque para realizar o registro utilizando *wavelets* as imagens devem estar com a mesma resolução, e o resultado obtido é o conjunto de informações de ambas as imagens.

2.4.2 SURF (*Speeded-Up Robust Features*)

A tarefa de encontrar pontos correspondentes entre duas imagens faz parte de muitas aplicações de processamento de imagens e visão computacional. Esta tarefa pode ser dividida em três etapas principais. Em primeiro lugar, os pontos de interesse são selecionados em locais distintos da imagem, como cantos, por exemplo. Em seguida, a vizinhança de todos os pontos de interesse é representada por um vetor de pontos (descritores). Finalmente, os vetores descritores são combinados entre imagens diferentes. A correspondência é baseada em uma distância entre os vetores, como a distância euclidiana (BAY, 2007).

O detector mais utilizado é provavelmente o detector de cantos conhecido como Harris, proposto em 1988. Ele experimentou tanto a determinante da matriz de Hessian, bem como a Laplaciana. A matriz hessiana é a matriz quadrada das derivadas parciais de segunda ordem da função. A matriz laplaciana é a representação matricial de um gráfico. O método foi aperfeiçoado, e foi criado então o detector Harris Laplaciano e Hessian Laplaciano (BAY, 2007).

Para fazer a detecção dos pontos de interesse, o algoritmo SURF utiliza uma aproximação da matriz Hessiana. O algoritmo também faz o uso de imagens integrais para reduzir drasticamente o tempo de computação, pois elas possibilitam uma rápida computação de convoluções baseadas em filtros de caixa (NOVAIS, 2016).

Um campo qualquer de uma imagem integral $I_{\Sigma}(x')$, localizado em $x' = (x, y)$ representa a soma de todos os pixels da imagem de entrada I dentro de uma região retangular formada pelas coordenadas da origem da imagem I e por x' (Equação 2.7).

$$I_{\Sigma}(x') = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq y} I(i, j) \quad (2.7)$$

David Lowe introduziu a distribuição de características baseadas em pontos vizinhos. O descritor SIFT, por exemplo, calcula um histograma de gradientes orientados localmente em torno do ponto de interesse e armazena as informações em um vetor (BAY, 2007).

Para fazer a descrição dos pontos chave, o primeiro passo do algoritmo, é a identificação da orientação dos pontos chave. Para isso, primeiramente são calculadas as respostas dos filtros das wavelets de Haar nas direções x e y dentro de uma vizinhança circular de raio igual à $6s$ ao redor do ponto de interesse, sendo s a escala na qual o ponto de interesse foi detectado. Então, novamente o algoritmo usa as imagens integrais para uma rápida filtragem. O resultado é um vetor com informações do ponto detectado e seus vizinhos (NOVAIS, 2016).

Nesta pesquisa, o algoritmo SURF foi utilizado para realizar o registro entre as imagens em baixa definição dos sistemas segmentados, com as imagens em alta definição da base VHD. Isto foi feito para gerar uma máscara, para extração na base de dados VHD das informações em alta definição. O algoritmo SURF será comparado com a abordagem proposta neste trabalho para imagens em ultra-alta definição.

2.5 BASES DE DADOS DE IMAGENS MÉDICAS HUMANAS COLORIDAS

O processo de congelar corpos humanos para o estudo anatômico teve seu início em março de 1870 e ficou conhecido como a “Era do gelo” (AL-GAILANI, 2016). O anatomista Wilhelm Braune recebeu em seu instituto, em Leipzig, o corpo de uma jovem que se enforcara no final do período de gravidez. Em vez de dissecar o cadáver, Braune congelou o cadáver da mulher e depois cortou-o verticalmente ao meio para produzir as primeiras seções congeladas de um corpo humano (Figura 2.4).


Esse processo foi muito questionado pelos educadores médicos, pois a dissecação era essencial para o estudo de corpos humanos na época e não se imaginava os benefícios que

poderiam trazer para a área educacional. O mesmo autor apresenta o “*Visible Human*” como o primeiro conjunto criogênico fotografado digitalmente (AL-GAILANI, 2016).

A seguir serão abordadas as bases de dados de imagens médicas humanas coloridas *Visible Human Database* (VHD) e a *Segmented Inner Organs* (SIO), utilizadas nesta pesquisa.

Figura 2.4: Litografias a cores de um cadáver congelado contendo o útero e o feto (58 x 39 cm) do artista C.

Schmiedel. Atlas folio de Wilhelm Braune, publicado simultaneamente em inglês e alemão. Cortesia da Biblioteca Nacional de Medicina.



Fonte: AL-GAILANI, 2016

2.5.1 *The Visible Human Database*

O *The Visible Human Database* é uma base de dados de imagens médicas e foi criada para servir no auxílio ao diagnóstico de doenças, planejamentos cirúrgicos, e atlas anatômico (em um ambiente de realidade virtual, por exemplo, para o ensino dos componentes do corpo humano) (ACKERMAN, 1998).

Teve início em julho de 1986, quando Michael Ackerman (Chefe do Departamento de Tecnologia Educacional da *National Library of Medicine* (NLM) ficou impressionado com os avanços na área de imagens digitais obtidas por Cornelius Rosse (Presidente do Departamento de Estrutura Biológica na Universidade de Washington), e começou a estudar uma parceria entre a Universidade de Washington e a NLM (BAATZ, 2004). Em 1987 o projeto foi discutido pela primeira vez, a princípio sem o conhecimento de como construir, armazenar, e distribuir as imagens (ACKERMAN, 1996).

Em 1989 apareceram as primeiras preocupações com o projeto, pois segundo as estimativas o tamanho dos arquivos seria de 20 GB (vinte gigabytes), para a época aproximadamente vinte mil disquetes, o que tornaria inviável a distribuição, pois levaria quase dois anos para ser feita a transferência de um local a outro. Mas prevendo os avanços tecnológicos, Ackerman prosseguiu o projeto embasado na frase dita pelo cientista da computação Alan Kane: “A única maneira bem-sucedida de prever o futuro é inventá-lo” (ACKERMAN, 1996).


Em abril de 1990, a Biblioteca Nacional de Medicina apresentou um relatório com as recomendações feitas pela *Long Range Plan of the Board of Regents* em 1987, para que fosse verificada a viabilidade de construir uma biblioteca de imagens biomédicas, tendo em vista as inovações que o projeto proporcionaria para a educação e a pesquisa. Em novembro do mesmo ano, no “*Symposium on Computer Application in Medical Care*”, foi anunciado os tipos de

aquisição das imagens do projeto: tomografia computadorizada, ressonância magnética e fotografias coloridas de um cadáver fatiado com precisão milimétrica (MASYS, 1990).

Após dois anos de pesquisa, as estimativas para o conjunto de imagens ultrapassaram 40 GB (quarenta gigabytes) de memória e o armazenamento seria feito em aproximadamente setenta CD-ROM, gerando problemas na distribuição das imagens (VANNIER, 1992).

Em vinte e oito de novembro de 1994, a NLM disponibilizou o primeiro conjunto de dados digitais anatômicos do corpo humano masculino, formado por imagens de RM obtidas em intervalos de 4mm com resolução de 256x256 pixels, imagens de TC em intervalos de 1 mm, com resolução de 512x512 pixels e imagens anatômicas obtidas por fotografia com secções transversais anatômicas em intervalos de 1 mm para coincidir com as imagens axiais de TC, com resolução de 2048x1216 pixels, sendo o pixel de 0,33 mm de tamanho e 24 bits de cor. A Figura 2.5 mostra uma das 1871 imagens coloridas capturadas, sendo o tamanho de cada imagem de 7,5 MB (megabytes). Todo o processo de aquisição das imagens e a preparação do corpo é descrito em Spitzer (1996).

Figura 2.5: Fotografia de 70mm de uma fatia (plano axial) de 0,33mm de espessura do corpo criogenado



Fonte: U.S. National Library of Medicine, 2019

Um ano após, a NLM divulgou o conjunto de dados do sexo feminino, com 5189 imagens anatômicas axiais obtidas em intervalos de 0,33 mm, tornando possível a reconstrução tridimensional com voxels cúbicos (U.S. National Library of Medicine, 2019). A resolução foi de 4096x2700 pixels. A mulher tinha 59 anos, 1,67cm e 72kg.

Na Figura 2.6 é ilustrado os corpos masculino e feminino reconstituídos no plano coronal. Observa-se que a imagem não é contínua, apresentando 4 (quatro) divisões, pois o cadáver foi congelado em blocos que não ultrapassavam 51 cm (SPTIZER, 2018), sendo essa a principal crítica dos coreanos e o motivo para a criação de um novo banco de imagens.

Figura 2.6: Reconstrução da seção frontal do homem (esquerda) e da mulher (direita) mostrada na mesma escala



Fonte: Spitzer, 1998

Os dados dos cadáveres, masculino e feminino, que compõem a base de dados são mostrados no Quadro 2.3.


Quadro 2.3: Dados dos Cadáveres que Compõem a Base VHD

Base de dados	Sexo	Idade	Peso (kg)	Altura (m)
Cadáver 1	Masculino	38	-	-
Cadáver 2	Feminino	59	-	-

Fonte: SPITZER, 1998

A Figura 2.7 exibe alguns cortes axiais do cadáver masculino com os respectivos nomes de arquivos.

Figura 2.7: Imagens axiais em ultra-alta definição do cadáver masculino



Fonte: Base de Dados VHD

Outras bases de dados surgiram a partir desta. O projeto *The Visible Korean Human* (VKH) surgiu da dificuldade de adaptar a anatomia dos coreanos em forma e tamanho às imagens disponíveis pelo VHP dos corpos americanos (CHUNG, 2002). Outros problemas identificados foram a perda de informação entre os blocos, a espessura dos cortes de 0,33 mm que torna difícil identificar estruturas menores e a diferença de 1mm e 0,33 mm na aquisição das imagens dos corpos masculino e feminino.

Visando aprimorar equipamentos e métodos, foram realizados vários experimentos, no intervalo de março de 1996 a fevereiro de 2001. O primeiro trabalho apresentado pelos coreanos foi publicado em 2000 e refere-se apenas ao processo de aquisição das imagens do cérebro, de um homem de cinquenta e oito anos, sendo produzido cento e trinta imagens com intervalo de 1.4 mm de 300x360 de RM e coloridas (CHUNG, 2002). Esse mesmo autor apresentou imagens do coração, do pulmão e dos pés, com intervalos de cortes de 10 mm e resolução de 2160x1440 de imagens coloridas (PARK, 2006).


Outro projeto foi o *The Chinese Visible Project*, que segundo *China Education and Research Network* (2018), as primeiras imagens obtidas a partir de um corpo humano real chinês foram obtidas em novembro de 1998. Em dezembro de 2000 foi apresentado os dados do *Shanghai Visible Human* (SVH) de um corpo masculino, mas foi em novembro de 2001, na "*Xiangshan Science Conference*", em Pequim, que o projeto *Chinese Visible Human* (CVH) foi incluído no *National Development Project of High-Tech Research* (ZHANG, 2004; QI, 2007).

2.5.2 *The Segmented Inner Organs*

Baseada no projeto *The Voxel-Man*, a *The Segmented Inner Organs* (SIO) é uma base de dados de imagens dos órgãos internos do cadáver masculino da base VHD com mais de duzentos objetos anatômicos segmentados e rotulados, onde as imagens coloridas foram reduzidas para a resolução de 573x330, e foi aplicado um método de segmentação adaptado de um método interativo, baseado no limiar (segmentação rgb-Elipsoide) seguido por morfologia matemática binária e rotulagem de componentes conectados. Segundo Tiede, Schiemann e Hohne (1998), o processo de segmentação foi iniciado com o registro das imagens coloridas às imagens de TC, permitindo a segmentação dos ossos, o que contribuiu para a segmentação dos órgãos.

A Figura 2.8 apresenta a imagem colorida, a TC e a segmentada.

Figura 2.8: Segmentação dos órgãos do corpo humano da base SIO



Fonte: <<https://www.voxel-man.com/segmented-inner-organs-of-the-visible-human/>>

O método de registro utilizado consiste em estabelecer pontos de referência entre as imagens coloridas e as imagens de TC, usados posteriormente para calcular a função de mapeamento entre as imagens (SCHIEMANN, 1994; SCHIEMANN, 1996).

Em relação à segmentação, para estruturas mais detalhadas, a segmentação manual foi necessária (SCHIEMANN, 1997; POMMERT, 2001) devido à complexidade e a falta de algoritmos eficientes para este tipo de imagem.

Segundo Pommert et al. (2006), a visualização do volume dos órgãos renderizados utilizou *ray casting*, com textura, sendo esse o modelo gerado pela base SIO. Esse tipo de modelo perde a qualidade de cor e de textura, original ao corpo humano, tornando fácil a visualização, mas não representando o original.

Essa base de imagens tem contribuído no estudo para a segmentação das imagens em alta definição, permitindo identificar cada parte do sistema, bem como a formação de cada um deles através dos órgãos constituintes.

A base de dados SIO, originalmente, foi segmentada por órgãos, em baixa definição, como mostra o Quadro 2.4 (exibe dados apenas parte dos órgãos da cabeça). Os arquivos estão em duas pastas distintas, a pasta *head* (com órgãos que fazem parte da cabeça), e pasta *inner organs* (com os arquivos do restante dos órgãos internos do corpo humano). Um

arquivo armazena o rótulo (*label*) de cada um dos órgãos, para cada uma das pastas. Este rótulo especifica a pasta que faz referência aos arquivos daquele determinado órgão.

2.6 REVISÃO DA LITERATURA SOBRE APLICAÇÕES UTILIZANDO A BASE VHD

Esta seção aborda a revisão da literatura realizada acerca das aplicações utilizando a base VHD. A principal motivação era identificar as aplicações desta base relacionadas com a segmentação e o registro de imagens médicas coloridas.

Quadro 2.4: Segmentação por órgãos da base SIO

Pasta	Órgão	Tradução	Label
Head	atlas C1	Atlas C1	6507
Head	axis C2	Eixo C2	6508
Head	Brain	Cérebro	5158
Head	cervical vertebra C3	Vértebra cervical C3	6509
Head	cervical vertebra C4	Vértebra cervical C4	6510
Head	cervical vertebra C5	Vértebra cervical C5	6511
Head	cervical vertebra C6	Vértebra cervical C6	6512
Head	cranium	Crânio	5149
Head	frontal sinus	Seio frontal	5178
Head	grey matter	Massa cinzenta	4598
Head	hyoid bone	Osso hióide (fica na parte anterior do pescoço)	6545
Head	larynx	Laringe	5161
Head	left eye	Olho esquerdo	5156
Head	left lens	Lente esquerda	5177
Head	left maxillary sinus	Seio maxilar esquerdo	5180

Fonte: Adaptado de SPITZER, 1998

A *string* utilizada para a pesquisa foi: (("visible human project" OR "visible human dataset" OR "visible human database") AND ("image segmentation" OR "image registration")).

No Quadro 2.5 são apresentadas as bases eletrônicas que foram utilizadas e os respectivos links, sendo selecionada quatro bases. As duas primeiras estão ligadas às ciências exatas e engenharia, a Institute of Electrical and Electronics Engineers (IEEE) e a Assocation for Computing Machinery (ACM), e as demais são bases multidisciplinares, a Springer Link e a Science Direct. A pesquisa não apresentou restrição ao período, optou-se por publicação em periódicos, sendo a *string* pesquisada em todo o texto e a última busca foi realizada em 26 de junho de 2019, resultando em 150 artigos.

Quadro 2.5: Bases pesquisadas

Base	Classificação	Endereço da Base
IEEE	Ciências Exatas	< https://ieeexplore.ieee.org/search/advsearch.jsp?expression-builder >
ACM	Ciências Exatas	< https://dl.acm.org/ >
Springer Link	Multidisciplinares	< https://rd.springer.com/ >
Science Direct	Multidisciplinares	< https://www.sciencedirect.com/ >

Fonte: Autoria Própria

Para a busca dos artigos foram utilizados os seguintes critérios de inclusão: publicações do tipo artigos completos e em inglês. Quanto aos critérios de exclusão foram os seguintes: artigos que não apresentam a descrição detalhada da base a que se referia ou artigos que não tratam da base VHD e imagens que não apresentassem alguma informação referente a imagens coloridas. Mediante a aplicação dos critérios de inclusão e exclusão foram selecionadas oito referências, assim distribuídas conforme a Quadro 2.6: seis artigos da IEEE, zero artigos da ACM, um artigo da Springer Link e um artigo da Science Direct.

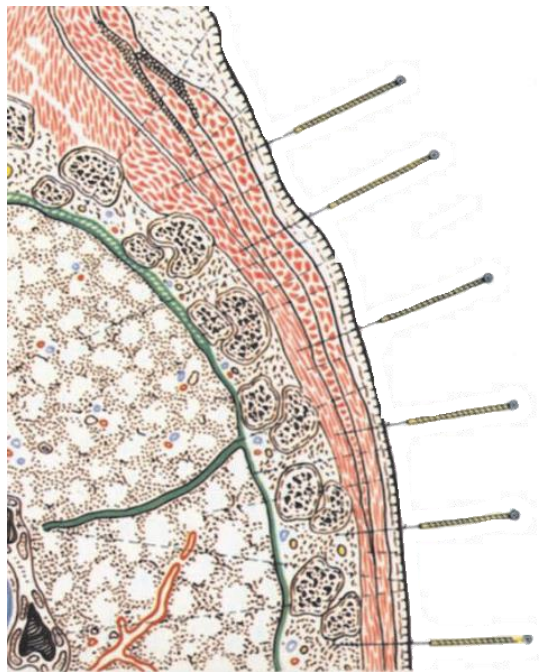
De forma sucinta, são descritos os oito artigos selecionados, abordando o objetivo do trabalho e o método utilizado.

2.6.1 Segmentação dos Músculos para Representação 3D de Pontos para a Acupuntura

No artigo de Zheng (2004) utilizou-se a base de dados masculina do *Visible Human*, para implementar uma ferramenta que realiza a segmentação dos músculos para a marcação de pontos para o tratamento baseado em acupuntura. Para a segmentação, o trabalho descreve um método de elipsoide dupla no espaço de cores RGB (ZHENG, 2004).

A Figura 2.9 mostra a importância da identificação dos músculos para a marcação dos pontos.

Figura 2.9: Importância da identificação dos músculos para a marcação dos pontos



Fonte: ZHENG, 2004

Este trabalho está baseado na ferramenta *The Voxel-Man* e detalha a técnica utilizada para a segmentação do sistema muscular do corpo humano.

2.6.2 *Segmentação, Reconstrução e Visualização da artéria pulmonar e da veia pulmonar de Imagens Anatômicas da VHD*

Flores (2005) em seu artigo descreve a extração da artéria pulmonar e da veia pulmonar do corpo masculino da base VHD, utilizando imagens coloridas anatômicas. A segmentação usa uma abordagem baseada no crescimento da região (*3D-region growing*) combinada com uma abordagem baseada em contornos e morfologia (FLORES, 2005).

2.6.3 *Simulador Interativo de Dissecção de Cadáveres*

A dissecção de cadáveres é uma ferramenta valiosa no ensino de anatomia. Com as restrições práticas que os professores de anatomia enfrentam hoje, eles procuram melhorar a qualidade de ensino usando métodos novos auxiliados por computador.

Karunasekara (2009) propõe a implementação de um simulador de dissecção de cadáveres baseado em imagens anatômicas digitais. O simulador seria usado como uma ferramenta de laboratório para se familiarizar com o processo de dissecção. Os alunos podem interagir com a ferramenta e definir um órgão ou uma área de uma região a ser removida. Definindo e removendo cada órgão/região sucessivos, a dissecção poderia ser realizada como está sendo feito no laboratório.

A cor original verdadeira é preservada no volume renderizado para transmitir uma real experiência aos alunos. As imagens originais foram pré-processadas pelo "*The Visible Human Preprocessing Toolkit*", plug-in do ImageJ. O processamento adicional foi feito através do *Visualization Toolkit* (VTK) para remover *patches* desnecessários que permaneceram no fundo. A segmentação foi realizada pelo plug-in "LiveWire" no ImageJ (KARUNASEKARA, 2009).

2.6.4 Visualização e Segmentação do Sistema Cardíaco

No trabalho de Yang (2009) é descrita a visualização do coração segmentado gerado a partir da base VHD. Adotou-se o algoritmo de *ray casting* para a renderização do volume. A ferramenta fornece as opções de rotação e *zoom*, e de planos de cortes para uma melhor visualização (YANG, 2009).


2.6.5 Segmentação Automatizada da Medula Espinhal

A segmentação da região da medula espinhal é um passo importante na análise automatizada de doenças neurológicas, como a esclerose múltipla, por exemplo. Vários estudos científicos mostram a conexão entre a progressão de doenças neurológicas associadas com a atrofia medular ou alterações em sua estrutura (SRHIDAR, 2018).

O método proposto por Srhidar (2018) utiliza discos ativos circulares e um algoritmo de crescimento de região. Os resultados obtidos foram promissores em relação aos índices de sensibilidade, especificidade, precisão e Jaccard (SRHIDAR, 2018).

A Figura 2.10 mostra o resultado do método, comparando-o com uma segmentação manual (*ground truth*).

Figura 2.10: Resultado do método proposto no artigo




Fonte: SRHIDAR, 2018

A Figura 2.10a mostra a imagem original. A Figura 2.10b exibe a segmentação manual. E a Figura 2.10c mostra o resultado da segmentação utilizando o método proposto no trabalho.

A Figura 2.11 mostra o desafio da segmentação da medula espinhal.

Figura 2.11: Segmentação da medula espinhal



Fonte: SRHIDAR, 2018

2.6.6 *Visualização do Coração a Partir de Imagens Seccionadas Utilizando uma Função de Transferência Híbrida*

No trabalho desenvolvido por Xia (2014) a visualização do coração segmentado favorece a pesquisa de patologias, planejamento pré-cirúrgico e abordagem clínica. O resultado da segmentação também permite visualizar toda a região do peito mostrando o espaço ocupado pelo coração. Para realizar a segmentação foi proposta uma técnica híbrida de transferência (XIA, 2014).

2.6.7 *Segmentação e Reconstrução de Veias Hepáticas e Intra-Hepáticas Utilizando a Base Coronal VHD*

A reconstrução tridimensional intra-hepática de vasos é muito útil na visualização do complexo anatômico das veias hepáticas e das veias intra-hepáticas. Isto fornece uma base para o diagnóstico por imagem e operação de cirurgias no fígado. (LOU, 2009).

A segmentação obtida por Lou (2009), neste trabalho, foi realizada de forma manual, utilizando a ferramenta photoshop.

2.6.8 *Segmentação de Imagens Baseada em Rastreamento Adaptativo de Contornos Ativos Geométricos*

A segmentação é um dos grandes desafios da pesquisa humana digital. Este processo geralmente é realizado por profissionais especialistas, com conhecimento de anatomia humana. O artigo de Chen (2013) apresenta um método de rastreamento de contorno de imagens geométrico adaptativo. O algoritmo leva em consideração o grau de correspondência entre os pontos do contorno do objeto, variação de gradiente, cores do objeto e do plano de fundo (CHEN, 2013).

O Quadro 2.6 mostra um resumo dos artigos selecionados.

Neste estudo, mesmo com a redução do escopo, apontam que a principal aplicação utilizando a base de dados VHD está relacionada a segmentação de imagens do corpo humano. Artigos que tratassem de registro de imagens utilizando a base VHD com imagens coloridas não foram encontrados. Foram identificadas duas ferramentas de segmentação, o Photoshop e a biblioteca ImageJ juntamente com o VTK, e dentre as técnicas de segmentação a região de crescimento foi a mais utilizada. Um dos artigos discutiu o desenvolvimento de um simulador de dissecação de cadáveres, que é onde esta pesquisa será aplicada. Verificou-se também que na maioria dos trabalhos há a presença de imagens sintéticas, retocadas ou

pintadas, diferentemente da proposta desta pesquisa que é exibir imagens realistas do corpo humano.

Quadro 2.6: Resumo das aplicações utilizando a base VHD

Autor	Ano	Aplicação	Técnica Utilizada
ZHENG	2004	Segmentação dos Músculos	Elipsoide dupla no espaço de cores RGB
FLORES	2005	Segmentação da Artéria e Veia Pulmonar	3D- <i>region growing</i>
KARUNASEKARA	2009	Simulador de Dissecção de Cadáveres	Bibliotecas ImageJ e VTK
YANG	2009	Visualização da Segmentação do Coração	Algoritmo de <i>ray casting</i>
SRHIDAR	2018	Segmentação da Medula Espinhal	Discos ativos circulares e um algoritmo de crescimento de região (<i>region growing</i>)
XIA	2014	Visualização do Coração Segmentado	Função Híbrida de Transferência
LOU	2009	Segmentação e Reconstrução de Veia Hepáticas e Intra-Hepáticas	Ferramenta Photoshop
CHEN	2013	Segmentação de dados digitais humanos	Rastreamento Adaptativo de Contornos Ativos Geométricos

Fonte: Autoria Própria

Este mapeamento contribuiu para identificação dos métodos adotados para a segmentação e registro das bases de imagens coloridas de corpos humanos congelados, servindo com um ponto de partida para novos estudos de na área de segmentação e registro.

2.7 CONSIDERAÇÕES FINAIS

Neste trabalho foram utilizadas duas bases de dados, a base VHD e a base SIO. A segmentação dos órgãos da base SIO foi utilizada para gerar uma máscara aplicada à base VHD, para gerar os modelos em ultra-alta definição dos sistemas do corpo humano.

A segmentação utilizada nesta proposta baseia-se na segmentação por região e utiliza a técnica de registro de imagens. Foi aplicado um registro não rígido, afim, para a correção

da escala, da translação e da rotação, nas imagens SIO em baixa resolução, para ajuste da resolução em relação às imagens da base VHD.

Neste Capítulo foi apresentada a fundamentação teórica necessária para a elaboração e compreensão deste trabalho. Foram apresentados os conceitos de imagens médicas e discutido a segmentação e o registro de imagens médicas. Algumas técnicas de registro de imagens foram discutidas na sequência. Por fim, foram apresentadas as bases de imagens médicas coloridas utilizadas na pesquisa e algumas aplicações utilizando a base VHD.

No próximo Capítulo é realizada uma descrição dos materiais e métodos utilizados para a segmentação dos sistemas do corpo humano, da base de dados do projeto *The Visible Human Body*, para a geração de imagens volumétricas com acuidade visual.

CAPÍTULO 3

3 MATERIAIS E MÉTODOS

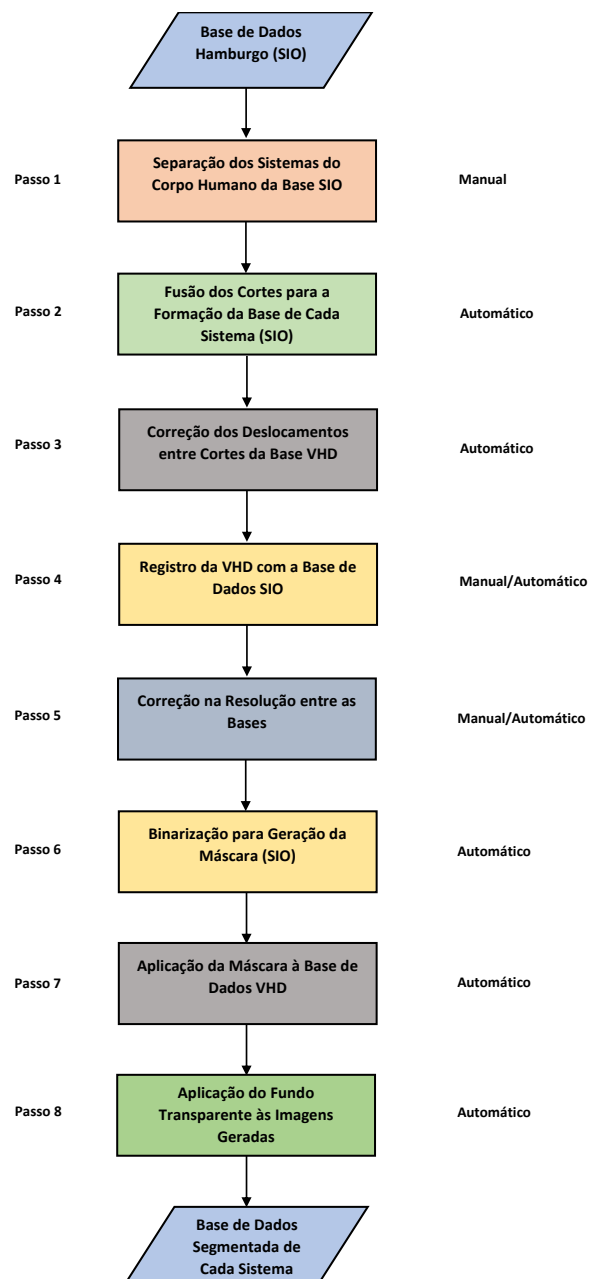
Este Capítulo aborda a metodologia utilizada para realizar a segmentação de imagens em ultra-alta definição, 2K, da base VHD, dos sistemas do corpo humano, utilizando técnicas de registro de imagens, para a geração de modelos volumétricos com acuidade visual. Neste contexto, na Seção 3.2 é abordada a base de dados utilizada no trabalho. Na seção 3.3 é descrito as ferramentas computacionais de imagens médicas utilizadas. Na Seção 3.4 é apresentada a abordagem proposta, descrevendo cada uma das etapas que a compõe. Os métodos de validação serão descritos na seção 3.5 e as considerações finais estão na seção 3.6.

O intuito da pesquisa é realizar a segmentação de imagens em ultra-alta definição, 2K, da base VHD, dos sistemas esquelético, circulatório, digestório, nervoso e respiratório do corpo humano, usando como modelos de referência imagens em baixa definição (imagens de TC ou de RM), utilizando técnicas de registro de imagens, para a geração de modelos volumétricos com acuidade visual. Baseado em trabalhos descritos na literatura e experimentos realizados, foi elaborada uma abordagem para a implementação deste processo.

A visão geral (fluxograma) da abordagem semiautomática proposta é apresentada na Figura 3.1. Ela divide-se em oito etapas, a saber, a separação dos sistemas do corpo humano da base SIO, a fusão dos cortes para a formação da base de cada sistema, a correção dos

deslocamentos entre cortes da base VHD, o registro da VHD com a base de dados SIO, a correção na resolução entre as bases, a binarização para a geração da máscara da base SIO, a aplicação da máscara à base de dados VHD, e a aplicação do fundo transparente às imagens, gerando uma visualização tridimensional de cada sistema do corpo humano, em alta resolução, com acuidade visual.

Figura 3.1: Fluxograma da abordagem proposta



Fonte: Autoria Própria

A pesquisa faz parte de um projeto chamado The Visible Human Table (VHT). É um simulador de dissecação para o estudo de anatomia composto por duas partes, um hardware projetado para prover os requisitos de usabilidade e desempenho, e um software que é usado como uma ferramenta de aprendizado pelos usuários da mesa digital. Suporta resoluções de até 4K e um corpo humano com aproximadamente 1.70m (para representação em tamanho real).

3.1 BASE DE DADOS DE IMAGENS COLORIDAS UTILIZADAS

Para a realização do trabalho, foram utilizados dados do cadáver masculino da base do *Visible Human Database*, conjunto de dados de imagem digital colorida de cadáveres humanos em ultra-alta definição. Esta base foi escolhida por ser referência em trabalhos de pesquisa relacionados ao ensino da anatomia humana.

Também foi utilizada a base de dados de imagens SIO, composta por órgãos segmentados do corpo masculino da base VHD.

3.2 FERRAMENTA COMPUTACIONAL UTILIZADA

O software utilizado para a implementação da abordagem proposta, que faz a segmentação dos sistemas do corpo humano em ultra-alta definição, utilizando o registro de imagens, foi o Matlab.

O Matlab é um software comercial que pode ser utilizado em várias aplicações, incluindo processamento de imagens e estatísticas. O programa fornece um ambiente de programação e muitas bibliotecas implementadas que auxiliam o desenvolvimento de aplicações.

3.3 ABORDAGEM PROPOSTA PARA A SEGMENTAÇÃO DOS SISTEMAS DO CORPO HUMANO EM ULTRA-ALTA DEFINIÇÃO

A abordagem divide-se em oito etapas, a saber, a separação dos sistemas do corpo humano da base SIO, a fusão dos cortes para a formação da base de cada sistema, a correção dos deslocamentos entre cortes da base VHD, o registro da base VHD com a base de dados SIO, a correção na resolução entre as bases, a binarização para a geração da máscara da base SIO, a aplicação da máscara à base de dados VHD, e a aplicação do fundo transparente às imagens, gerando uma visualização tridimensional de cada sistema do corpo humano, em alta resolução, com acuidade visual.

Nas próximas subseções são apresentadas e detalhadas as etapas para o desenvolvimento da abordagem proposta.

3.3.1 *Separação dos Sistemas do Corpo Humano da Base SIO*

A primeira etapa foi unir os órgãos aos sistemas do corpo humano, separando os arquivos por sistemas. O Quadro 3.1 mostra parte do trabalho de unir os órgãos aos seus respectivos sistemas.

3.3.2 *Fusão dos Cortes para a Formação da Base de Cada Sistema*

Por causa da separação inicial da base SIO por órgãos, informações de um mesmo corte poderiam estar separadas nos diversos arquivos de órgãos do corpo humano. A segunda etapa foi unir as informações de um mesmo corte, por sistema.

A Figura 3.2 mostra duas imagens, de órgãos diferentes, com informações de um mesmo corte. Por exemplo, a label 5180 (seio maxilar direito), e a label 5179 (seio maxilar esquerdo), fazem parte do sistema respiratório. Elas contêm cortes iguais (por exemplo, o corte 1140), mas as informações estão separadas em cada um dos órgãos. Desta forma, o

desafio nesta etapa foi unir as informações pertencentes a um mesmo corte, de um mesmo sistema.

Quadro 3.1: Segmentação por órgãos e por sistema da base SIO

Pasta	Órgão	Tradução	Label	Sistema
Head	atlas C1	Atlas C1	6507	Esquelético
Head	axis C2	Eixo C2	6508	Esquelético
Head	Brain	Cérebro	5158	Nervoso
Head	cervical vertebra C3	Vértebra cervical C3	6509	Esquelético
Head	cervical vertebra C4	Vértebra cervical C4	6510	Esquelético
Head	cervical vertebra C5	Vértebra cervical C5	6511	Esquelético
Head	cervical vertebra C6	Vértebra cervical C6	6512	Esquelético
Head	cranium	Crânio	5149	Esquelético
Head	frontal sinus	Seio frontal	5178	Respiratório
Head	grey matter	Massa cinzenta	4598	Nervoso
Head	hyoid bone	Osso híóide (fica na parte anterior do pescoço)	6545	Esquelético
Head	larynx	Laringe	5161	Respiratório
Head	left eye	Olho esquerdo	5156	Sensorial
Head	left lens	Lente esquerda	5177	Sensorial
Head	left maxillary sinus	Seio maxilar esquerdo	5180	Respiratório
Head	left palatine tonsil	Tonsila palatina esquerda	4596	Linfático

Fonte: Autoria Própria

Figura 3.2: Duas imagens, de órgãos diferentes, com informações de um mesmo corte



Fonte: Imagem da base SIO

A Figura 3.3 mostra a imagem com as informações fundidas.

Figura 3.3: Imagem com as informações fundidas



Fonte: Autoria Própria

O algoritmo utilizado percorreu cortes de mesmo nome, pertencentes a um mesmo sistema, unindo em um único corte as informações que estavam em arquivos distintos (Figura 3.4).

Figura 3.4: Algoritmo para fusão das informações de um mesmo corte

ALGORITMO: Fusão das informações de um mesmo corte

Entrada: Todos os cortes (imagens) de um determinado sistema

Saída: Fusão das informações de um mesmo corte

$\text{ImgFusao} \leftarrow \text{Fusao_cortes}(\text{Img1}, \text{Img2});$

Fonte: Autoria Própria

3.3.3 Correção dos Deslocamentos entre Cortes da VHD

Esta fase consiste em corrigir os deslocamentos encontrados entre algumas faixas de imagens da base VHD. Isto porque alguns cortes não se alinham perfeitamente em relação a outros. A correção foi feita com base na Quadro 3.2, e aplica-se ao plano horizontal. O Quadro 3.2 mostra a faixa de cortes com o valor dos seus respectivos deslocamentos implementados.

Quadro 3.2: Deslocamentos entre os cortes da base VHD

Cortes	Deslocamentos (pixels)
1231 à 1252	9
1253 à 1360	-2
1361 à 1390	11
1391 à 1416	-2
1417 à 1729	11
1730 à 1790	17
1791 à 1880	18
1881 à 2546	16
2547 à 2702	18
2703 à 2878	20

Fonte: <sites.utexas.edu/austinmanaustinwomanmodels/am-shifts/>

3.3.4 Registro da base de dados SIO com a base de dados VHD

Para o registro da base de dados SIO com a VHD foi utilizado um método semiautomático. O primeiro passo foi seleccionar os pontos coincidentes entre uma imagem da base SIO, e a mesmo corte da base VHD. Após a seleção do corte e a definição dos pontos coincidentes, foi gerada uma transformação a partir da diferença entre os pontos seleccionados. O critério utilizado para escolher o corte para o registro foi a maior quantidade de *pixels*

presente para a formação da imagem. Para isto, um algoritmo foi implementado para fazer a contagem e a comparação do total de pixels das diversas imagens presentes em um determinado sistema do corpo humano.

O Quadro 3.3 apresenta o corte selecionado para cada sistema do corpo humano no qual a abordagem foi aplicada. A transformação obtida a partir do registro dessas imagens seria aplicada a todas as outras do mesmo sistema.

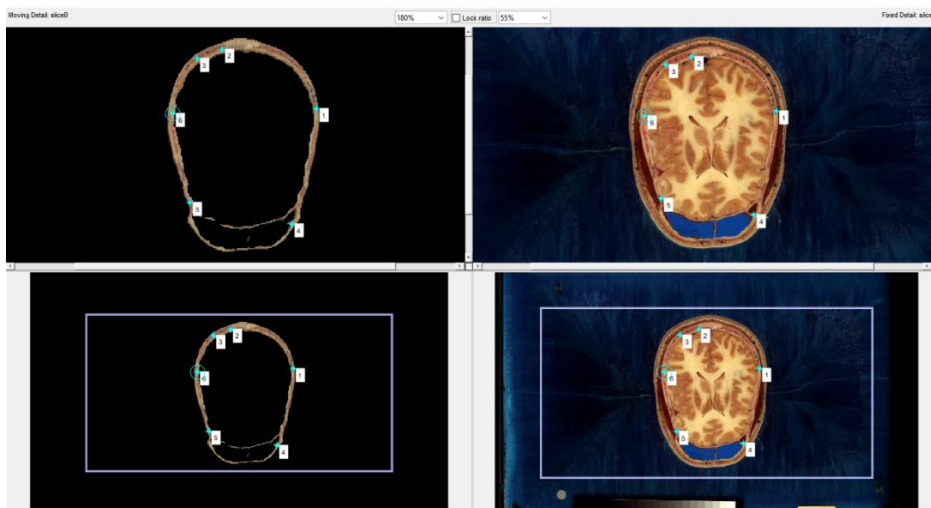
Quadro 3.3: Número do corte utilizado para o alinhamento para cada sistema

Sistema do Corpo Humano	Número do Corte Escolhido
Sistema Circulatório	1450
Sistema Digestivo	1530
Sistema Esquelético	1080
Sistema Nervoso	1090
Sistema Respiratório	1420

Fonte: Autoria Própria

A Figura 3.5 mostra a tela interativa onde os pontos coincidentes foram selecionados.


Figura 3.5: Seleção dos pontos coincidentes entre a base SIO e a VHD



Fonte: Autoria Própria

A ferramenta permite a seleção de no mínimo três pontos coincidentes. Quanto mais pontos são marcados, melhor o resultado do registro. Uma curva da quantidade de pontos em relação à qualidade do registro é mostrada na Figura 3.6, utilizando-se o índice de similaridade estrutural (SSIM). Percebe-se que a partir do sexto ponto indicado a curva de qualidade das imagens registradas estabiliza-se.

Figura 3.6: Quantidade de seleção de pontos em relação ao resultado do registro



Fonte: Autoria Própria

O segundo passo foi exportar os pontos para duas variáveis. Estas informações seriam usadas para obter a transformação (rotação, translação e escala) que seria aplicada em toda a base do sistema escolhido (Figura 3.7).

Figura 3.7: Algoritmo para o registro de imagens

ALGORITMO: Registro de Imagens

Entrada: Mesmo corte de imagem, do mesmo sistema, em baixa resolução e em alta resolução

Saída: Transformação (translação, rotação e escala para obter, a partir da imagem em baixa resolução, uma imagem em alta resolução)

tform ← Obter_transformacao(movingPoints, fixedPoints, tipoTransformacao);

Fonte: Autoria Própria

A Figura 3.8 mostra a o algoritmo para aplicar a transformação a todas as imagens em baixa definição. Para realizar este passo, foi utilizada a interpolação linear de pontos por vizinhos próximos.

Figura 3.8: Algoritmo para aplicação do registro de imagens

ALGORITMO: Aplicar Registro às Imagens
Entrada: Todas as imagens em baixa definição
Saída: Aplicação da transformação a todas as imagens em baixa definição

```

Para cont ← inicio : fim
    ImgEntrada ← Ler_imagem(NomeArquivo);
    registro ← Aplicar_transformacao(ImgEntrada, tform);
    Escrever_imagem(registro, NomeArquivo);
Fim para

```

Fonte: Autoria Própria

3.3.5 Correção na Resolução entre as Bases

Nesta fase é feito a adição de linhas ou colunas, no início ou no final da imagem, para correção da resolução, para a perfeita aplicação da máscara às imagens da base VHD (Figura 3.9).

Figura 3.9: Algoritmo para correção na resolução

ALGORITMO: Correção na Resolução
Entrada: Imagens após a aplicação do registro
Saída: Imagens com a mesma resolução das imagens da base VHD

```


ImgCorrigido ← Correcao_resolucao(ImgEntrada,[linhas_adicionadas
colunas_adicionadas],'replicar_primeira','inicio');
ImgCorrigido ← Correcao_resolucao(ImgCorrigido,[linhas_adicionadas
colunas_adicionadas],'replicar_ultima','fim');

```

Fonte: Autoria Própria

A Figura 3.10 mostra a tela em que este processo de ajuste é realizado. Na imagem é possível verificar que ambas as imagens estão perfeitamente alinhadas e com a mesma resolução, após as correções aplicadas.

Figura 3.10: Correção e ajuste no registro entre as bases



Fonte: Autoria Própria


A imagem verde, corresponde ao corte da VHD. A imagem rosa, corresponde a base SIO.

3.3.6 *Binarização para a geração da máscara da base SIO*

A binarização é a última etapa na construção da máscara que será aplicada à base VHD, para obter as informações desejadas. Na binarização, a imagem de saída terá todos os pixels da imagem de entrada com luminância maior do que o nível especificado demarcados pela cor branca e para os demais pixels a cor preta. A binarização foi aplicada com limiar de 0.1, e pode ser visualizada na Figura 3.11.

A Figura 3.12 exhibe o algoritmo para a binarização das imagens.

Figura 3.11: Binarização das imagens da base SIO para a geração da máscara



Fonte: Autoria Própria

Figura 3.12: Algoritmo para binarização das imagens

ALGORITMO: Binarização das Imagens
Entrada: Imagem registrada e com a resolução corrigida
Saída: Imagens binarizadas
$ImgBin \leftarrow \text{binarizacao}(ImgSaida, Limiar);$

Fonte: Autoria Própria

3.3.7 Aplicação da Máscara à Base de Dados VHD

Nesta etapa, aplica-se a máscara obtida com a base SIO, à base VHD, para obter o modelo em ultra-alta definição, 2k ou 4k (Figura 3.13). O resultado dos processos anteriormente descritos gerou uma imagem considerada a máscara da região de interesse, permitindo que todo o restante da imagem pudesse ser descartado. Através da máscara, que serve como um delimitador de região, foi possível realizar a segmentação de cada sistema do corpo humano.

A Figura 3.14 exibe o algoritmo para a binarização das imagens.

Figura 3.13: Aplicação da máscara à base VHD



Fonte: Autoria Própria

Figura 3.14: Algoritmo para aplicação da máscara

ALGORITMO: Aplicação da máscara às imagens da base VHD

Entrada: Imagens binarizadas (máscaras) e imagens da base VHD

Saída: Imagens segmentadas a partir da base VHD

Para cont ← inicio : fim

 ImgMascara ← Ler_imagem(NomeArquivo);

 ImgVHD ← Ler_imagem(NomeArquivo);

 Para linha ← inicio : fim

 Para coluna ← inicio : fim

 Se (ImgMascara(linha,coluna) = 1) // Não for um pixel preto

 ImgSaida(linha,coluna,red) ← ImgVHD(linha,coluna,red);

 ImgSaida(linha,coluna,green) ← ImgVHD(linha,coluna,green);

 ImgSaida(linha,coluna,blue) ← ImgVHD(linha,coluna,blue);

 Senão

 ImgSaida(linha,coluna,red) ← ImgVHD(linha1,coluna1,red); // aplicar preto

 ImgSaida(linha,coluna,green) ← ImgVHD(linha1,coluna1,green); // aplicar preto

 ImgSaida(linha,coluna,blue) ← ImgVHD(linha1,coluna1,blue); // aplicar preto

 Fim se

 Fim para

 Fim para

Fim para

Fonte: Autoria Própria

3.3.8 Aplicação do Fundo Transparente às Imagens

Esta é a última etapa, a aplicação do fundo transparente às imagens. Isto foi importante para a visualização de todos os cortes em um plano tridimensional. Para isso utilizou-se o formato Portable Network Graphics (PNG) aplicando uma máscara, ao obter os pixels brancos externos à imagem, no canal alfa da imagem e como esse formato permite comprimir imagens, mantendo a qualidade, aplicou-se a máscara nos três canais da imagem colorida, no canal R, no G e no B. Após a aplicação do fundo transparente, é possível visualizar todo o sistema segmentado, em um ambiente tridimensional, com acuidade visual.

A Figura 3.15 exhibe o algoritmo para a binarização das imagens.

Figura 3.15: Algoritmo para aplicação do fundo transparente

ALGORITMO: Fundo transparente às imagens

Entrada: Imagens segmentadas

Saída: Imagens segmentadas com o fundo transparente

Para cont ← início : fim

 ImgFinal ← Canal_alpha(ImgEntrada, AjusteAlpha);

 Escrever_imagem(ImgFinal, NomeArquivo);

Fim para

Fonte: Autoria Própria

3.3.9 Visualização do Sistema Segmentado


A Figura 3.16 mostra o sistema esquelético segmentado, em ultra-alta definição. O ambiente volumétrico permite visualizar o modelo em diversos ângulos.

3.4 VALIDAÇÃO DA ABORDAGEM PROPOSTA

A fim de avaliar a abordagem proposta para o registro de imagens médicas coloridas em ultra-alta definição, serão utilizadas algumas métricas quantitativas. Os resultados serão validados através das métricas de performance e similaridade *peak signal to noise ratio* (PSNR), do *mean square error* (MSE) e da soma do quadrado das diferenças (SQD) (SAHU,

2012). Em relação à segmentação, serão utilizados os coeficientes de similaridade Jaccard (J) e Dice (D), e os parâmetros de sensibilidade (S), especificidade (E) e acurácia (A). O objetivo é analisar a similaridade e diversidade de conjuntos de características (SIEGA, 2015).

Figura 3.16: Sistema segmentado em ultra-alta definição



Fonte: Autoria Própria

3.4.1 Mean Square Error (MSE)

O MSE, erro médio quadrático, apresenta o quanto os erros ocorrem no sistema (Equação 3.2). M e N são o número de linhas e colunas das imagens de entrada respectivamente. I_1 matriz de valores de intensidade para a primeira imagem de entrada. I_2 matriz de valores de intensidade para a segunda imagem de entrada.

$$MSE = \frac{\sum_{M,N}[I_1(m,n) - I_2(m,n)]^2}{M * N} \quad (3.2)$$

3.4.2 Peak Signal to Noise Ratio (PSNR)

PSNR significa relação de pico de sinal e ruído. É uma expressão para a razão dos valores máximos possíveis (potência) de um sinal e a potência do ruído distorcido que afeta a qualidade de sua representação. Quanto maior o valor, melhor será o resultado. A Equação 3.1 mostra como calculá-la. R é a flutuação máxima no tipo de dado da imagem de entrada.

Por exemplo, se a imagem de entrada tiver um tipo de dado ponto flutuante de precisão dupla, então R será 1. Se ele tiver um tipo de dado inteiro de 8 *bits*, R será 255.

$$PSNR = 10 \cdot \log_{10} \left(\frac{R^2}{MSE} \right) \quad (3.1)$$

3.4.3 Similaridade Estrutural (SSIM)

O índice de similaridade estrutural é uma métrica de qualidade de imagem que avalia o impacto visual de três características de uma imagem: luminância, contraste e estrutura. A Equação 3.2 mostra como calculá-lo.

$$SSIM_{(x,y)} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3.2)$$

Onde μ_x é a média de x , μ_y é a média de y , σ_x é a variância de x , σ_y é a variância de y e σ_{xy} é a covariância de x e y . $C_1 = (K_1L)^2$, $C_2 = (K_2L)^2$, duas variáveis para estabilizar o denominador da divisão. L o intervalo dinâmico dos valores de pixel. $k_1 = 0.01$ e $k_2 = 0.03$ por padrão.

3.4.4 Coeficiente de Similaridade Jaccard (J)

Jaccard é um dos coeficientes mais utilizados na representação de similaridades entre conjuntos, e é representado pela Equação 3.3.

$$J = \frac{a}{a + b + c} \quad (3.3)$$

Sendo que “a” representa o sistema esquelético na imagem segmentada manualmente e na imagem processada, “b” representa o sistema esquelético somente na imagem segmentada manualmente e “c” é o sistema esquelético somente na imagem processada.

3.4.5 Coeficiente de Similaridade Dice (*D*)

O coeficiente de similaridade Dice é um coeficiente baseado no coeficiente de Jaccard, porém atribui peso maior ao atributo de similaridade as duas imagens (Equação 3.4).

$$D = \frac{2a}{2a + b + c} \quad (3.4)$$

3.4.6 Teste de Sensibilidade (*S*)

O teste de sensibilidade (*S*) representa a capacidade que o método proposto tem de identificar o sistema esquelético quando é realmente este sistema. Quanto menor o número de falsos negativos (FN) mais sensível será o processo. A sensibilidade é calculada pela Equação 3.5, sendo que VP é o número de verdadeiros positivos.

$$S = \frac{VP}{VP + FN} \quad (3.5)$$

3.4.7 Teste de Especificidade (*E*)

A especificidade (*E*) determina a capacidade de não encontrar o sistema esquelético na imagem segmentada quando realmente não existe no *ground truth*. Quanto menor o número de falsos positivos (FP) mais específico será o processo. A Equação 3.6 é utilizada para verificar a especificidade, onde VN representa o número de verdadeiros negativos.

$$E = \frac{VN}{VN + FP} \quad (3.6)$$

3.4.8 *Teste de Acurácia (A)*

E, por fim, é calculada a acurácia (A), sendo a proporção de resultados corretos no total das imagens, refletindo a precisão do processo comparado as imagens segmentadas manualmente. A Equação 3.7 apresenta a maneira de se calcular a acurácia. VP é a quantidade de verdadeiros positivos, VN a quantidade de verdadeiros negativos, FP a quantidade de falsos positivos e FN a quantidade de falsos negativos.

$$A = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.7)$$

3.5 CONSIDERAÇÕES FINAIS

Este Capítulo apresentou as etapas do método proposto neste trabalho para a realização do processo de segmentação dos sistemas do corpo humano, da base VHD, em ultra-alta definição, utilizando registro de imagens. No próximo Capítulo são apresentados os experimentos e resultados obtidos.

CAPÍTULO 4


4 EXPERIMENTOS E RESULTADOS OBTIDOS

Este Capítulo aborda os experimentos e resultados obtidos a partir da abordagem proposta para realizar a segmentação de imagens em ultra-alta definição, 2K, da base VHD, dos sistemas esquelético, circulatório, digestório, nervoso e respiratório do corpo humano, usando como modelos de referência imagens em baixa definição (imagens de tomografia computadorizada ou de ressonância magnética), utilizando técnicas de registro de imagens, para a geração de modelos volumétricos com acuidade visual.

4.1 ANÁLISE DO MÉTODO DE SEGMENTAÇÃO

Computacionalmente, em imagens médicas, muitas técnicas acabam tendo dificuldades para segmentar imagens em ultra-alta definição, por serem imagens complexas. O desafio desta pesquisa foi segmentar as imagens dos sistemas do corpo humano em 2k da base VHD. Cinco sistemas do corpo humano foram escolhidos: o sistema esquelético, o sistema circulatório, o sistema digestório, o sistema nervoso e o sistema respiratório. O primeiro sistema do corpo humano seguímentado foi o sistema esquelético. A Figura 4.1 mostra algumas imagens presentes na base VHD e identifica o tecido ósseo a ser segmentado, mostrando a complexidade da proposta da pesquisa.

Figura 4.1: Desafio da pesquisa – segmentação do sistema esquelético




Fonte: Imagens da base VHD

Os maiores problemas para a segmentação estão relacionados a quantidade de detalhes e tecidos presentes nas mesmas. Em todas as imagens, Figura 4.1a, Figura 4.1b, Figura 4.1c, Figura 4.1d, Figura 4.1e e Figura 4.1f, as setas apontam para o tecido ósseo presente nas imagens. É possível perceber que a cor deste tecido se assemelha muito a outros tecidos, tornando o processo complexo.

A segmentação proposta dos sistemas do corpo humano será utilizada no projeto intitulado mesa de dissecação virtual, e possibilitará com que os usuários analisem sistemas específicos do corpo humano, podendo aproximar uma determinada parte da imagem, fazer a navegação e visualização nos três planos, axial, sagital e coronal, bem como fazer as anotações necessárias e armazenar estas informações.

A Figura 4.2 apresenta os mesmos cortes da Figura 4.1, porém segmentados, utilizando o método proposto.

Figura 4.2: Segmentação do sistema esquelético



Fonte: Autoria Própria


A Figura 4.2a, Figura 4.2b e Figura 4.2c exibem os tecidos ósseos segmentados da cabeça. Já a Figura 4.2d, Figura 4.2e e Figura 4.2f mostram o sistema esquelético do tórax humano.

4.2 PROBLEMAS NA SEGMENTAÇÃO EM ULTRA-ALTA DEFINIÇÃO

As imagens em ultra-alta definição possuem um alta grau de complexidade, tornando o processo de segmentação uma tarefa difícil. Desta forma, utilizou-se neste trabalho uma abordagem diferenciada. Foram utilizadas as imagens segmentadas da Universidade de Hamburgo, base de dados SIO, em baixa definição, para a segmentação dos sistemas do corpo humano em alta definição da base VHD, utilizando o registro de imagens. Para isto, utilizou-se a base SIO para gerar uma máscara, que foi aplicada à base VHD, gerando imagens segmentadas com acuidade visual.

A Figura 4.3 compara o resultado obtido com a segmentação da abordagem proposta, e a segmentação da Universidade da Hamburgo, em baixa definição. A imagem foi aproximada para uma melhor visualização e comparação.

Figura 4.3: Comparação entre o método proposto e uma imagem segmentada da Universidade de Hamburgo



Fonte: (a) Autoria Própria. (b) Imagem da base SIO

É possível verificar visualmente que a imagem segmentada com o método proposto neste trabalho apresenta maiores detalhes e uma definição melhor que a imagem da base SIO, além de cores e texturas realistas.

4.3 EXPERIMENTOS REALIZADOS E ANÁLISE DOS RESULTADOS

Foram realizados três experimentos. O primeiro experimento comparou o registro semiautomático proposto com dois métodos de registro automático. O segundo comparou os resultados gerados com a abordagem proposta neste trabalho em relação a um *ground truth* de imagens segmentadas manualmente. No terceiro experimento, comparou-se os resultados gerados com a abordagem deste trabalho em relação aos resultados da base SIO de Hamburgo.

4.3.1 Primeiro Experimento


O primeiro experimento comparou o método semiautomático proposto com outro método automático presente na literatura, o algoritmo SURF.

Uma questão a ser avaliada é optar por algoritmos que façam o registro, e não a fusão das imagens. Registro está associado ao alinhamento das imagens (rotação, translação, e em determinados algoritmos a escala). Fusão está associada a junção de informações. As wavelets, por exemplo, são usadas para realizar a fusão entre duas imagens. Por isso o algoritmo exige que ambas as imagens estejam em uma mesma resolução. O algoritmo implementado não conseguiu realizar o ajuste da escala.

Os resultados no registro automático com o algoritmo SURF mostram a dificuldade em realizar o alinhamento entre imagens complexas em ultra-alta definição. A Figura 4.4 mostra a identificação errada de pontos equivalentes obtidas pelo SURF, gerando um resultado não satisfatório.

Não foi possível fazer uma análise do experimento, tendo em visto que o método de registro SURF não conseguiu, com eficiência, identificar os pontos coincidentes entre as imagens. As razões estão associadas à complexidade das imagens em 2K e o alto nível de complexidade das informações. Desta forma, uma imagem distorcida foi gerada.

Figura 4.4: Registro automático com o algoritmo SURF



Fonte: Autoria Própria

4.3.2 Segundo Experimento

No segundo experimento, criou-se um *ground truth* de imagens segmentadas manualmente através de uma ferramenta gráfica de edição e comparou-as com a segmentação proposta no trabalho.

Foi utilizado o sistema esquelético para descrever as etapas do processo da segmentação proposta, discutindo em cada etapa os problemas encontrados e os resultados obtidos.

A abordagem divide-se em oito etapas, a saber, a separação dos sistemas do corpo humano da base SIO, a fusão dos cortes para a formação da base de cada sistema, a correção dos deslocamentos entre cortes da base VHD, o registro da base VHD com a base de dados SIO, a correção na resolução entre as bases, a binarização para a geração da máscara da base SIO, a aplicação da máscara à base de dados VHD, e a aplicação do fundo transparente às

imagens, gerando uma visualização tridimensional de cada sistema do corpo humano, em alta resolução.

A primeira etapa da abordagem proposta consiste em identificar os órgãos que fazem parte do sistema esquelético, separando os arquivos necessários para a posterior segmentação. O Quadro 3.4 mostra os órgãos da cabeça pertencentes a este sistema. As *labels* indicam as pastas com os arquivos referentes a um determinado órgão. Este processo foi feito de forma manual.

Quadro 3.4: Identificação dos órgãos do sistema esquelético

Pasta	Órgão	Tradução	Label	Sistema
Head	cervical vertebra C3	vértebra cervical C3	6509	Esquelético
Head	cervical vertebra C4	vértebra cervical C4	6510	Esquelético
Head	cervical vertebra C5	vértebra cervical C5	6511	Esquelético
Head	cervical vertebra C6	vértebra cervical C6	6512	Esquelético
Head	cranium	crânio	5149	Esquelético
Head	hyoid bone	osso hióide (fica na parte anterior do pescoço)	6545	Esquelético
Head	left styloid process	processo estiloide esquerdo	5153	Esquelético
Head	mandible	mandíbula	5152	Esquelético
Head	right styloid process	processo estiloide direito	5154	Esquelético

Fonte: Autoria Própria

A segunda etapa consiste na fusão dos cortes para a formação da base do sistema esquelético. Para exemplificar, foram selecionadas as labels 6570 e 6571, referente aos ossos da mão esquerda e direita respectivamente. As labels representam as pastas que contém os

arquivos daquele órgão do corpo. Analisando as pastas 6570 e 6571, é possível verificar que existe, em ambas, o corte 1800. Isto porque na pasta 6570 estão as informações dos ossos da mão esquerda, e na pasta 6571 as informações dos ossos da mão direita. É necessário então fazer a fusão das informações, gerando um único corte 1800 com ambas as informações (Figura 4.5).

Figura 4.5: Duas imagens, de órgãos diferentes do sistema esquelético, com informações de um mesmo corte



Fonte: Imagem da base SIO

A Figura 4.6 mostra a imagem com as informações fundidas.

Figura 4.6: Imagem com as informações fundidas



Fonte: Autoria Própria

Isto foi feito com todos os cortes do sistema esquelético. O algoritmo implementado percorre todos os cortes fazendo a junção das informações de cortes iguais.

A próxima fase consiste na correção dos deslocamentos entre cortes da base VHD. A correção é feita com base no Quadro 3.2 e aplica-se ao plano horizontal. As três primeiras etapas correspondem a alguns processos de pré-processamento das bases SIO e VHD antes do registro das imagens.

A etapa seguinte diz respeito ao registro da base de dados esquelética SIO com a base de dados VHD. O objetivo é corrigir a translação, rotação e escala das imagens da base SIO,

em relação à base VHD. Primeiramente, são selecionados os pontos coincidentes entre as imagens. O ideal é selecionar seis ou sete pontos, de acordo com a Figura 3.5. O critério utilizado para escolher o corte para o registro é maior quantidade de *pixels* para a formação da imagem. Uma transformação é gerada e aplicada a todas as imagens da base SIO.

Nesta etapa, a precisão de seleção dos pontos é muito importante. Se os pontos não forem corretamente selecionados, o registro das imagens não será realizado de forma satisfatória. Desta forma, pode ser necessário repetir o processo de seleção dos pontos até que se encontre uma transformação precisa. Um software foi implementado para visualizar o registro das imagens da base SIO juntamente com a mesma imagem da base VHD sobreposta, com cores diferentes. Visualmente é possível identificar se o processo foi ou não bem sucedido.

A próxima etapa é a correção na resolução entre as bases. O registro gera imagens com resoluções diferentes das imagens da base VHD. Desta forma, é necessário a inserção de colunas ou linhas ao final da imagem. Em casos em que a imagem registrada não ficou perfeitamente ajustada à imagem fixa da base VHD, foi necessário a inserção de linhas ou colunas no início da imagem. Esta correção foi realizada de forma manual, podendo ser desenvolvido e pesquisado um algoritmo que realize este processo de forma automática.

Os benefícios dos processos manuais para o registro, em especial em imagens de ultra-alta definição, é que se obtém pontos coincidentes mais precisos em relação aos processos automáticos. Porém, a falta de precisão do usuário acarreta um tempo maior na realização dos processos e exige certa habilidade do usuário para um melhor resultado.

A etapa seguinte corresponde à de binarização da base esquelética SIO para a geração de uma máscara, posteriormente aplicada à base VHD. A penúltima etapa foi a aplicação propriamente dita da máscara à base de dados VHD. O sucesso do processo depende muito da precisão da segmentação da base SIO. Este processo proposto nesta pesquisa apenas gera a mesma segmentação da base de dados SIO, com uma resolução melhor das imagens.

A última etapa é a aplicação do fundo transparente às imagens geradas e por fim, a visualização do sistema esquelético segmentado, como mostra a Figura 4.7.

Figura 4.7: Sistema esquelético em ultra-alta definição



Fonte: Autoria Própria

Após a segmentação, as imagens geradas pela abordagem proposta foram então comparadas com imagens segmentadas de forma manual. A Figura 4.8 mostra duas imagens, o corte 1080 da base segmentada do sistema esquelético e o mesmo corte segmentado de forma manual.

Figura 4.8: Comparação entre o método proposto e uma imagem segmentada manualmente



(a) Método Proposto




(b) Segmentação Manual (*Ground Truth*)

Fonte: Autoria Própria

Visualmente, percebe-se a diferença ao aumentar o *zoom* (Figura 4.9). Algumas falhas na segmentação do método proposto são percebidas em razão da segmentação ruim da base SIO. Uma melhora na segmentação em baixa definição iria proporcionar um resultado melhor.

Figura 4.9: Comparação entre o método proposto e uma imagem segmentada manualmente (com zoom)



Fonte: Autoria Própria

A Tabela 4.1 mostra os resultados do segundo experimento. Percebe-se que a precisão do processo, representado pelo índice de acurácia, é em média de 98,95%. A similaridade entre as imagens geradas pelo método e manualmente é de 98,30%, em média, de acordo com o coeficiente de Jaccard, e de 99,12%, em média, de acordo com o coeficiente de Dice.

Tabela 4.1: Resultados do Segundo Experimento

IMG	TOTAL SEG. MAN. (pixels)	TOTAL SEG. SEM. (pixels)	VP (pixels)	VN (pixels)	FN (pixels)	FP (pixels)	S	E	A	J	D
1021	29876	39833	29816	1704103	60	10017	99,79%	99,41%	99,42%	100%	100%
1080	25289	32687	23684	1709704	1605	9003	93,65%	99,47%	99,39%	99,45%	99,72%
1300	62738	85175	51270	1647353	11468	33905	81,72%	97,98%	97,39%	93,75%	96,77%
2029	8906	12554	7259	1729795	1647	5295	81,50%	99,69%	99,60%	100%	100%
Média									98,95%	98,30%	99,12%


IMG = número da fatia utilizada; TOTAL SEG. MAN. = total de pixels que representam os ossos na imagem ground truth; TOTAL SEG. SEM. = total de pixels que representam os ossos na imagem segmentada com a abordagem desta pesquisa; VP = número de pixels para verdadeiro positivo; VN = número de pixels para verdadeiro negativo; FN = número de pixels para falso negativo; FP = número de pixels para falso positivo; S = percentual de sensibilidade; E = percentual de especificidade; A = percentual de acurácia; J = percentual de similaridade com coeficiente de Jaccard; D = percentual de similaridade com o coeficiente de Dice.

Fonte: Autoria Própria

A Figura 4.10 mostra graficamente a diferença dos percentuais de acurácia, de similaridade com o coeficiente de Jaccard e Dice em relação às imagens comparadas.

A Tabela 4.2 apresenta o resultado da segmentação utilizando a abordagem proposta no trabalho com uma imagem segmentada manualmente, utilizando as métricas PSNR, MSE e SSIM, que verificam a qualidade do registro, o quanto os erros ocorreram no processo de registro e a similaridade entre as imagens, respectivamente.

Figura 4.10: Diferença dos percentuais de sensibilidade, especificidade e acurácia



Fonte: Autoria Própria

Tabela 4.2: Resultados do segundo experimento – outras métricas

IMG	PSNR	MSE	SSIM
1021	28,6194	0,0013	99,13%
1080	29,6809	0,0010	98,63%
1300	21,8166	0,0065	95,71%
2029	29,0291	0,0012	99,35%
Média			98,20%

IMG = número da fatia utilizada; PSNR = relação sinal-ruído de pico (*Peak Signal-to-Noise Ratio*); MSE = Erro quadrático médio (*Mean-squared error*); SIM. ESTRUT. = índice de similaridade estrutural (*Structural Similarity Index*).

Fonte: Autoria Própria

O índice de similaridade estrutural entre as imagens, de acordo com a Tabela 4.2, é em média de 98,20%, mostrando a eficácia do método de registro. O valor do PSNR é medido em decibéis (dB), e valores aceitáveis para a perda de qualidade são considerados entre 20 dB e 25 dB, sendo considerado ótimo valores acima de 30 dB (THOMOS, 2005). Em relação ao MSE, quanto mais próximo o valor estiver de zero, melhor será o resultado. O resultado mostra valores significativos para esta métrica em relação às imagens. Os resultados obtidos, de um modo geral, indicam uma boa qualidade do registro.

4.3.3 Terceiro Experimento

O terceiro experimento comparou os resultados gerados com a abordagem deste trabalho em relação aos resultados da base SIO de Hamburgo.

A Figura 4.11 exibe a imagem segmentada com o método proposto e a imagem segmentada pela Universidade de Hamburgo (SIO).

Figura 4.11: Comparação entre o método proposto e uma imagem segmentada da Universidade de Hamburgo



(a) Método Proposto



(b) Segmentação Hamburgo

Fonte: Autoria Própria

A Figura 4.12 mostra a imagem segmentada com o método proposto e a imagem segmentada pela Universidade de Hamburgo (SIO), com aproximação em uma das partes das imagens.

Embora a estrutura das imagens seja a mesma, percebe-se a diferença na acuidade visual, no nível de detalhes mostrado, no conteúdo das imagens. No método proposto, a base SIO é utilizado apenas para gerar uma máscara, obtendo assim uma imagem em alta resolução.

Figura 4.12: Comparação entre o método proposto e uma imagem segmentada por Hamburgo (com zoom)



Fonte: Autoria Própria

A Tabela 4.3 mostra o resultado da comparação entre as imagens da base SIO, com resolução aumentada, em relação a uma imagem segmentada manualmente, utilizando três métodos que verificam a qualidade da imagem gerada.

Tabela 4.3: Resultados do terceiro experimento

IMG	PSNR	MSE	SSIM
1021	28,1031	0,0015	98,85%
1080	26,7052	0,0021	97,91%
1300	20,9259	0,0080	94,82%
2029	28,0222	0,0015	99,20%
Média			97,69%


IMG = número da fatia utilizada; PSNR = relação sinal-ruído de pico (*Peak Signal-to-Noise Ratio*); MSE = Erro quadrático médio (*Mean-squared error*); SIM. ESTRUT. = índice de similaridade estrutural (*Structural Similarity Index*).

Fonte: Autoria Própria

A Figura 4.13 mostra a comparação dos resultados das imagens da base SIO com as imagens geradas a partir da proposta desta pesquisa, através dos valores da métrica de similaridade estrutural.

O SSIM é um modelo baseado na percepção que considera a degradação da imagem como uma mudança percebida na informação estrutural, ao mesmo tempo que incorpora importantes fenômenos perceptivos, incluindo tanto o mascaramento de luminância quanto os termos de mascaramento de contraste. A informação estrutural é a ideia de que os pixels têm fortes interdependências, especialmente quando estão espacialmente próximos. Essas dependências carregam informações importantes sobre a estrutura dos objetos na cena visual. O mascaramento de luminância é um fenômeno pelo qual as distorções de imagem tendem a ser menos visíveis em regiões claras, enquanto o mascaramento de contraste é um fenômeno pelo qual distorções se tornam menos visíveis onde há atividade significativa ou textura na imagem.

Figura 4.13: Comparação dos resultados das imagens da base SIO com as imagens geradas a partir da proposta desta pesquisa, através da métrica de similaridade estrutural



Fonte: Autoria Própria

De acordo com os dados mostrados na Figura 4.13, observa-se que as imagens obtidas pelo método de segmentação da pesquisa obtiveram melhores resultados, comparando-as com as imagens em baixa definição da Universidade de Hamburgo, em relação à similaridade estrutural.


4.4 EXPERIMENTOS E ANÁLISE DE RESULTADOS COM OUTROS SISTEMAS DO CORPO HUMANO

Além do sistema esquelético, foram realizados experimentos com imagens dos sistemas circulatório, digestório, nervoso e respiratório.


Os sistemas foram segmentados utilizando o processo descrito nesta pesquisa, aplicado também ao sistema esquelético. Percebeu-se que, por causa do alinhamento das imagens, a transformação obtida através do registro aplicado ao sistema esquelético, poderia ser aplicada também a outros sistemas. Porém, nesta pesquisa, uma nova transformação foi obtida para cada sistema do corpo humano.

As Figuras 4.14a e 4.14b exibem imagens tridimensionais do sistema circulatório segmentado.

Figura 4.14: Sistema circulatório segmentado




(a) Sistema circulatório segmentado



(b) Sistema circulatório segmentado
rotacionado

As Figuras 4.15a e 4.15b mostram imagens tridimensionais do sistema digestório segmentado. As Figuras 4.16a e 4.16b exibem imagens tridimensionais do sistema nervoso segmentado.

Figura 4.15: Sistema digestório segmentado



(a) Sistema digestório segmentado



(b) Sistema digestório segmentado rotacionado

Fonte: Autoria Própria

Figura 4.16: Sistema nervoso segmentado



(a) Sistema nervoso segmentado



(b) Sistema nervoso segmentado rotacionado


Fonte: Autoria Própria

As Figuras 4.17a e 4.17b mostram imagens tridimensionais do sistema respiratório segmentado.

Figura 4.17: Sistema respiratório segmentado



(a) Sistema respiratório segmentado



(b) Sistema respiratório segmentado
rotacionado

Fonte: Autoria Própria

A Figura 4.18a exibe uma imagem do sistema circulatório segmentado utilizando a abordagem da pesquisa, e a Figura 4.18b, uma imagem da segmentação da base SIO.

Figura 4.18: Sistema circulatório segmentado com a abordagem proposta e da base SIO



(a) Abordagem proposta




(b) Base SIO

Fonte: Autoria Própria

É possível observar que as cores e texturas da Figura 4.15a são diferentes da Figura 4.15b. A imagem segmentada através da abordagem proposta expressa os tecidos realistas de um cadáver, enquanto a da esquerda é uma imagem sintética. Porém observa-se que os vasos pulmonares direito e esquerda são mais bem visualizados na imagem da base SIO. Por não ser perfeitamente preciso, o alinhamento do registro pode ter perdido detalhes destes vasos.

A Figura 4.19a mostra uma imagem do sistema digestório segmentado utilizando a abordagem da pesquisa, e a Figura 4.19b, uma imagem da segmentação da base SIO.

Figura 4.19: Sistema digestório segmentado com a abordagem proposta e da base SIO



Fonte: Autoria Própria

Além da percepção de profundidade percebida de forma mais clara na Figura 4.19a, as cores e texturas estão mais bem representadas. O gelo aparece nas imagens por falta de precisão na segmentação das imagens da base SIO.

A Figura 4.20a exibe uma imagem do sistema nervoso segmentado utilizando a abordagem da pesquisa, e a Figura 4.20b, uma imagem da segmentação da base SIO.

Observa-se na Figura 4.20a os detalhes dos sulcos cerebrais, além da precisão das cores e texturas. Também é possível perceber, na Figura 4.20a, o líquido cefalorraquidiano,

também conhecido como líquido ou fluido cérebro espinhal, que envolve o cérebro e faz a proteção contra algum choque.

Figura 4.20: Sistema nervoso segmentado com a abordagem proposta e da base SIO



(a) Abordagem proposta




(b) Base SIO


Fonte: Autoria Própria

A Figura 4.21a mostra uma imagem do sistema respiratório segmentado utilizando a abordagem da pesquisa, e a Figura 4.21b, uma imagem da segmentação da base SIO.

Figura 4.21: Sistema respiratório segmentado com a abordagem proposta e da base SIO



(a) Abordagem proposta



(b) Base SIO


Fonte: Autoria Própria

A Figura 4.21a mostra as cores, texturas e detalhes do sistema respiratório que a Figura 4.21b não exibe. O gelo que se manteve nas imagens é por causa das falhas de segmentação na imagem da base SIO.

Foi realizada uma análise comparando o resultado da segmentação utilizando a abordagem proposta no trabalho com uma imagem segmentada manualmente, utilizando um editor de imagens, para a geração de um *ground truth*.

A Figura 4.22a mostra uma imagem (um corte) do sistema circulatório segmentado utilizando a abordagem da pesquisa, e a Figura 4.22b, uma imagem da segmentação manual (*ground truth*).

Figura 4.22: Sistema circulatório segmentado com a abordagem proposta e com uma segmentação manual (*ground truth*)



(a) Abordagem proposta



(b) Segmentação manual (*ground truth*)

Fonte: Autoria Própria

A Figura 4.23a mostra uma imagem (um corte) do sistema digestório segmentado utilizando a abordagem da pesquisa, e a Figura 4.23b, uma imagem da segmentação manual (*ground truth*).

A Figura 4.24a mostra uma imagem (um corte) do sistema nervoso segmentado utilizando a abordagem da pesquisa, e a Figura 4.24b, uma imagem da segmentação manual (*ground truth*).

Figura 4.23: Sistema digestório segmentado com a abordagem proposta e com uma segmentação manual (*ground truth*)




(a) Abordagem proposta



(b) Segmentação manual (*ground truth*)

Fonte: Autoria Própria

Figura 4.24: Sistema nervoso segmentado com a abordagem proposta e com uma segmentação manual (*ground truth*)



(a) Abordagem proposta




(b) Segmentação manual (*ground truth*)

Fonte: Autoria Própria

A Figura 4.25a mostra uma imagem (um corte) do sistema respiratório segmentado utilizando a abordagem da pesquisa, e a Figura 4.25b, uma imagem da segmentação manual (*ground truth*).

A Tabela 4.4 mostra os dados obtidos, comparando a segmentação proposta com a segmentação manual, nos diversos sistemas do corpo humano segmentados.

Figura 4.25: Sistema respiratório segmentado com a abordagem proposta e com uma segmentação manual (*ground truth*)



(a) Abordagem proposta



(b) Segmentação manual (*ground truth*)

Fonte: Autoria Própria

Tabela 4.4: Resultados da Segmentação com a abordagem proposta na pesquisa em relação ao *ground truth*

IMG	TOTAL SEG. MAN. (pixels)	TOTAL SEG. SEM. (pixels)	VP (pixels)	VN (pixels)	FN (pixels)	FP (pixels)	S	E	A	J	D
1450 CIRC	39268	51498	37797	1691027	1471	13701	96,25%	99,19%	99,13%	91,57%	95,60%
1530 DIGE	154624	169627	148055	1567800	6569	21572	95,75%	98,64%	98,38%	99,51%	99,75%
1090 NERV	89639	114682	86256	1625931	3383	28426	96,22%	98,28%	98,17%	52,47%	68,82%
1420 RESP	92498	98922	88564	1641140	3934	10358	95,74%	99,37%	99,18%	94,11%	96,96%
Média									98,71%	84,41%	90,28%

IMG = número da fatia utilizada; TOTAL SEG. MAN. = total de pixels que representam os ossos na imagem *ground truth*; TOTAL SEG. SEM. = total de pixels que representam os ossos na imagem segmentada com a abordagem desta pesquisa; VP = número de pixels para verdadeiro positivo; VN = número de pixels para verdadeiro negativo; FN = número de pixels para falso negativo; FP = número de pixels para falso positivo; S = percentual de sensibilidade; E = percentual de especificidade; A = percentual de acurácia; J = percentual de similaridade com coeficiente de Jaccard; D = percentual de similaridade com o coeficiente de Dice.


Fonte: Autoria Própria

O percentual do coeficiente de Jaccard e Dice, para a imagem do sistema nervoso, foi de 52,47% e 68,82%, respectivamente. É possível concluir que a segmentação realizada na base SIO dos órgãos que compõem o sistema nervoso não foi satisfatória. As imagens dos tecidos nervosos são complexas e, portanto, de difícil segmentação.

A Figura 4.26 mostra graficamente a diferença dos percentuais de acurácia, coeficiente de Jaccard e Dice, das imagens obtidas pelo método proposto em relação às imagens segmentadas manualmente, para os diversos sistemas do corpo humano.

Com exceção do sistema nervoso, os outros sistemas apresentam valores que mostram índices consideráveis de similaridade entre as imagens geradas pelo método desenvolvido na pesquisa e a segmentação manual.

Figura 4.26: Diferença dos percentuais de sensibilidade, especificidade e acurácia



Fonte: Autoria Própria

4.5 APLICAÇÃO DA PESQUISA À UMA FERRAMENTA PARA O ESTUDO ANATÔMICO

Este trabalho de pesquisa faz parte de um projeto intitulado *Visible Human Table* (VHT), que é uma ferramenta de dissecação humana. Os benefícios estão relacionados a aprendizagem de anatomia humana em instituições de ensino, mas também pode ser utilizado em clínicas e hospitais para diagnóstico médico e treinamento pré-cirúrgico.

O VHT é um simulador de dissecação para o estudo de anatomia composto por duas partes, um hardware projetado para prover os requisitos de usabilidade e desempenho, e um

software que é usado como uma ferramenta de aprendizado pelos usuários da mesa digital. Suporta resoluções de até 4K e um corpo humano com aproximadamente 1.70m (BRONGEL, 2019).

A Figura 4.27 mostra a mesa de dissecação exibindo o sistema esquelético, segmentado pela abordagem proposta na pesquisa.

Figura 4.27: Mesa de dissecação exibindo o sistema esquelético segmentado pela abordagem proposta nesta pesquisa



Fonte: Autoria Própria

4.6 CONSIDERAÇÕES FINAIS

Este Capítulo apresentou uma análise e uma discussão detalhada dos resultados obtidos com os experimentos de validação do método proposto levando-se em consideração diferentes aspectos. Foram realizados alguns experimentos como a análise do método proposto com duas técnicas de segmentação automática, do método com uma segmentação manual, e

do método proposto com a segmentação da base SIO, utilizando métricas quantitativas para a análise dos cálculos.

Os resultados obtidos mostram a eficácia do método proposto para a segmentação dos sistemas do corpo humano, em ultra-alta definição, utilizando o registro de imagens, permitindo imagens com acuidade visual.

No próximo Capítulo são apresentadas as conclusões deste trabalho bem como sugestões de trabalhos futuros.

CAPÍTULO 5

5 CONCLUSÕES

Esta pesquisa apresentou uma abordagem para a segmentação de sistemas do corpo humano, em ultra-alta definição, como parte do projeto VHT, um ambiente 3D que auxilia os estudantes de medicina e áreas afins no aprendizado de anatomia, bem como auxiliam médicos e professores como uma ferramenta complementar em suas aulas.

O principal objetivo deste trabalho, portanto, foi realizar a segmentação de imagens em ultra-alta definição, 2K e 4K, da base VHD, dos sistemas esquelético, circulatório, digestório, nervoso e respiratório do corpo humano, usando como modelos de referência imagens em baixa definição (imagens de tomografia computadorizada ou de ressonância magnética), utilizando técnicas de registro de imagens. A base destina-se ao estudo da anatomia humana e foi usada para a geração de modelos volumétricos com acuidade visual.

Os resultados deste trabalho foram obtidos através da abordagem quantitativa. A abordagem foi comparada com outros algoritmos de registro de imagens, com uma segmentação manual (*ground truth*) e com as imagens da base SIO. Foram utilizadas várias métricas para aferir a viabilidade do método. A pesquisa indicou que o método é promissor tanto para a base VHD, como possivelmente para outras bases de imagens.

Algumas falhas na segmentação do método proposto são percebidas em razão da segmentação ruim da base SIO. Uma melhora na segmentação em baixa definição iria

proporcionar um resultado melhor na segmentação das imagens dos sistemas do corpo humano da base VHD.

Uma contribuição do trabalho está relacionada à nova abordagem para a segmentação dos sistemas do corpo humano, através de imagens coloridas em 2k, utilizando o registro de imagens, gerando um modelo volumétrico com acuidade visual. A combinação da segmentação das imagens em baixa resolução e a reconstrução em alta resolução, baseada no registro das imagens, possibilitou a geração de resultados promissores.

Como trabalhos futuros, espera-se realizar a segmentação em outros sistemas do corpo humano da base VHD. Testá-lo, também, em outras bases de imagens médicas disponíveis. Outra questão a ser pesquisada é realizar a segmentação dos sistemas do corpo humano, realizando primeiro a segmentação dos órgãos desse sistema. A fusão dos órgãos segmentados geraria o sistema a ser visualizado em um ambiente volumétrico.

Num contexto mais amplo, espera-se contribuir com o aprendizado dos alunos em cursos de anatomia e em ambientes médicos onde a ferramenta possa apoiar procedimentos cirúrgicos e tomadas de decisões por parte dos profissionais envolvidos.

Agradecemos a US National Library of Medicine pela aquisição e distribuição das imagens do The Visible Human Body Project (<https://www.nlm.nih.gov/research/visible/>), e ao The Voxel-Man Group (<https://www.voxel-man.com/>) por conceder as imagens segmentadas dos órgãos do corpo humano, que têm contribuído para o desenvolvimento dos estudos. Ao Instituto Federal do Paraná (IFPR), por ter concedido o afastamento que necessitei para a realização da pesquisa. Por fim, a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) por conceder a bolsa de estudos para cobrir as despesas de mensalidades do curso, bem como conceder uma bolsa de doutorado sanduíche para realizar parte do trabalho na Universidade do Porto, em Portugal.

6 REFERÊNCIAS BIBLIOGRÁFICAS

- ACKERMAN, Michael J. The visible human project. Proceedings of the IEEE, v. 86, n. 3, p. 504-511, 1998.
- AHIRWAR, Anamika. Study of techniques used for medical image segmentation and computation of statistical test for region classification of brain MRI. IJ Information Technology and Computer Science, v. 5, n. 5, p. 44-53, 2013.
- AL-GAILANI, S. The “Ice Age” of anatomy and obstetrics: hand and eye in the promotion of frozen sections around 1900. Bull Hist Med, 2016. Disponível em: <https://muse.jhu.edu/article/642727>. Acessado em: 10 Jul. 2019.
- ALY, Ashraf A.; DERIS, Safaai Bin; ZAKI, Nazar. Research review for digital image segmentation techniques. International Journal of Computer Science & Information Technology, v. 3, n. 5, p. 99, 2011.
- BANKMAN, Isaac N.; MORCOVESCU, Serban. Handbook of medical imaging. processing and analysis. Medical Physics, v. 29, n. 1, p. 107-107, 2002.
- BHASIN, Harsh; BHATIA, Surbhi. Application of genetic algorithms in machine learning. IJCSIT, v. 2, n. 5, p. 2412-2415, 2011.
- BASSETTE, F. Doeí meu corpo para o ensino da medicina. Folha de São Paulo – Ciência, 2009. Disponível em: <http://www1.folha.uol.com.br/ciencia/2009/04/553079-doei-meu-corpo-para-o-ensino-da-medicina-conta-ex-taxista.shtml>. Acessado em: 28 Mai. 2014.
- BAY, Herbert et al. Speeded-up robust features (SURF). Computer vision and image understanding, v. 110, n. 3, p. 346-359, 2008.
- BEVERIDGE, Erin et al. 3D visualization for education, diagnosis and treatment of iliotibial band syndrome. In: 2013 International Conference on Computer Medical Applications (ICCMMA). IEEE, 2013. p. 1-6.

- BRONGEL, Andrei Rafael; BROBOUSKI, WILLIAM JOHN PEREIRA; PIERIN, Lucas Murbach; GOMES, Carlos; ALMEIDA, Manoel de Campos; JUSTINO, Edson José Rodrigues. An Ultra-High Definition and Interactive Simulator for Human Dissection in Anatomic Learning. 11th International Conference on Computer Supported Education, n. CSEDU, p. 284–291, 2019.
- CHEN, Qiang; SUN, Quan-sen; XIA, De-shen. Serial slice image segmentation of digital human based on adaptive geometric active contour tracking. *Computers in biology and medicine*, v. 43, n. 6, p. 635-648, 2013.
- CHUNG, Min Suk et al. Visible Korean Human: Another trial for making serially sectioned images. In: *Medical Imaging 2002: Visualization, Image-Guided Procedures, and Display*. International Society for Optics and Photonics, 2002. p. 171-183.
- CHUNG, Min Suk et al. Trial for making other serially sectioned images (Visible Korean Human). In: *CARS 2002 Computer Assisted Radiology and Surgery*. Springer, Berlin, Heidelberg, 2002. p. 435-438.
- DALLEY, Gerald; FLYNN, Patrick. Range image registration: A software platform and empirical evaluation. In: *Proceedings Third International Conference on 3-D Digital Imaging and Modeling*. IEEE, 2001. p. 246-253.
- ELSEN, Petra A.; POL, E.-JD; VIERGEVER, Max A. Medical image matching-a review with classification. *IEEE Engineering in Medicine and Biology Magazine*, v. 12, n. 1, p. 26-39, 1993.
- FACON, J. *Morfologia Matemática: Teoria e Exemplos*. Editor Jacques Facon, Curitiba, 1996.
- FACON, J. *Metodologia de avaliação de abordagens de segmentação de imagens*. Technical report, Pontifícia Universidade Católica do Paraná, PUCPR, Curitiba, 2001.
- FITZPATRICK, J. M.; HILL, D. L. G.; MAURER, C. R. Image Registration. Disponível em: http://eecs.vanderbilt.edu/people/mikefitzpatrick/papers/2000_Fitzpatrick_HandbookII_Ch8_Registration.pdf. Acessado em: 18 ago. 2016.
- FLORES, Jorge Márquez; SCHMITT, F. Segmentation, reconstruction and visualization of the pulmonary artery and the pulmonary vein from anatomical images of the visible

human project. In: Sixth Mexican International Conference on Computer Science (ENC'05). IEEE, 2005. p. 136-144.

GONZALEZ, R. C.; WOODS, R. E. Digital Image Processing. 3 ed., New Jersey: Pearson, 2008.

HAJNAL, Joseph V.; HILL, Derek LG. Medical image registration. CRC press, 2001.

HARALICK, Robert M.; SHAPIRO, Linda G. Image segmentation techniques. Computer vision, graphics, and image processing, v. 29, n. 1, p. 100-132, 1985.

HELLIER, Pierre; BARILLOT, Christian. Coupling dense and landmark-based approaches for nonrigid registration. IEEE transactions on medical imaging, v. 22, n. 2, p. 217-227, 2003.

HILL, Derek LG et al. Medical image registration. Physics in medicine & biology, v. 46, n. 3, p. R1, 2001.

HUANG, Rui; PAVLOVIC, Vladimir; METAXAS, Dimitris N. A tightly coupled region-shape framework for 3D medical image segmentation. In: 3rd IEEE International Symposium on Biomedical Imaging: Nano to Macro, 2006. IEEE, 2006. p. 426-429.

HUO, Bingquan; LI, Guoxin; YIN, Fengling. Medical and Natural Image Segmentation Algorithm using MF based Optimization Model and Modified Fuzzy Clustering: A Novel Approach. International Journal of Signal Processing, Image Processing and Pattern Recognition, v. 8, n. 7, p. 223-234, 2015.

KARUNASEKARA, P. P. C. R.; DISSANAYAKE, M. M.; NANAYAKKARA, Nuwan D. An interactive cadaver dissection simulator. In: 2009 International Conference on Industrial and Information Systems (ICIIS). IEEE, 2009. p. 291-294.

KAUR, G.; CHHATERJI, J. A Survey on Medical Image Segmentation. International Journal of Science and Research (IJSR), 2017.

KAUR, Dilpreet; KAUR, Yadwinder. Various image segmentation techniques: a review. International Journal of Computer Science and Mobile Computing, v. 3, n. 5, p. 809-814, 2014.

- KAUSHIK, Divya et al. Medical image segmentation using genetic algorithm. *International Journal of Computer Applications*, v. 81, n. 18, p. 10-15, 2013.
- KUMAR, G. Anil; NISTALA, V.; MURTHY, E. S. Analysis of medical image processing and its applications in healthcare industry. *International Journal of Computer Technology & Applications*, v. 5, n. 3, p. 851-860, 2014.
- LASHARI, Saima Anwar; IBRAHIM, Rosziati. A framework for medical images classification using soft set. *Procedia Technology*, v. 11, p. 548-556, 2013.
- LIKAR, Bostjan; PERNUŠ, Franjo. A hierarchical approach to elastic registration based on mutual information. *Image and vision computing*, v. 19, n. 1-2, p. 33-44, 2001.
- LIMA, J. D., *Corpos reais para entender anatomia*. Gazeta do Povo, 2012. Disponível em: <https://www.gazetadopovo.com.br/educacao/corpos-reais-para-entender-anatomia-1d2ydx72l3loudjii8ots1rv2/>. Acessado em: 26 Mai. 2014.
- LOU, Li et al. Segmentation and reconstruction of hepatic veins and intrahepatic portal vein based on the coronal sectional anatomic dataset. *Surgical and radiologic anatomy*, v. 31, n. 10, p. 763, 2009.
- MAINTZ, JB Antoine; VIERGEVER, Max A. A survey of medical image registration. *Medical image analysis*, v. 2, n. 1, p. 1-36, 1998.
- MASYS, Daniel R. *Picture This... Developing Standards for Electronic Images at the National Library of Medicine*. In: *Proceedings of the Annual Symposium on Computer Application in Medical Care*. American Medical Informatics Association, 1990. p. 20.
- MISITI, Michel et al. *Matlab wavelet toolbox user's guide*. The MathWorks Inc., Natick, MA, USA, version, v. 2, 1996.
- NATIONAL LIBRARY OF MEDICINE (U.S.). *Visible Human Project Data*. Disponível em: <https://www.nlm.nih.gov/databases/download/vhp.html>. Acessado em: 01 Ago. 2019.
- SOVILJ-NIKIC, Sandra; SOVILJ-NIKIC, Ivan. Application of genetic algorithm in median filtering. In: *Proceedings of the International Multiconference on ISSN*. 2007. p. 7094.

- NOVAIS, JOZIEL PAULA. Aplicação dos Algoritmos SIFT e SURF na Classificação de Sub-Imagens por Discriminação de Textura. 2016.
- OLIVEIRA, Hélio Magalhaes. Análise de Sinais para Engenheiros: Uma abordagem via WAVELETS. Rio de Janeiro: Brasport, 2007.
- OLIVEIRA, Francisco PM; TAVARES, Joao Manuel RS. Medical image registration: a review. *Computer methods in biomechanics and biomedical engineering*, v. 17, n. 2, p. 73-93, 2014.
- PARK, Jin Seo et al. Visible Korean human: improved serially sectioned images of the entire body. *IEEE transactions on medical imaging*, v. 24, n. 3, p. 352-360, 2005.
- PARK, Jin Seo et al. Visible Korean Human: its techniques and applications. *Clinical Anatomy: The Official Journal of the American Association of Clinical Anatomists and the British Association of Clinical Anatomists*, v. 19, n. 3, p. 216-224, 2006.
- PATIL, D. D.; DEORE, S. G. Medical Image Segmentation. *IJCSMC*, 2013.
- PIANYKH, Oleg S. Digital imaging and communications in medicine (DICOM): a practical introduction and survival guide. Springer Science & Business Media, 2009.
- PINHEIRO, R. J. G. Definição de uma metodologia de Avaliação da Qualidade de Segmentação de Imagens. Curitiba, 2005, 101 p. Dissertação (Mestrado em Informática) - Programa de Pós-Graduação em Informática Aplicada – PPGIa, Pontifícia Universidade Católica do Paraná, 2005.
- POMMERT, Andreas et al. Computer-Based anatomy: A prerequisite for Computer-Assisted radiology and surgery¹. *Academic radiology*, v. 13, n. 1, p. 104-112, 2006.
- POMMERT, Andreas et al. Creating a high-resolution spatial/symbolic model of the inner organs based on the Visible Human. *Medical Image Analysis*, v. 5, n. 3, p. 221-228, 2001.
- QI, L.; ZHOU, G.; HAN, X.; DU, G.; CAO, H.; CHAI, H. et al. Reconstruction of the Digital Chinese Human. In: *Complex Medical Engineering. IEEE/ICME International Conference*, p. 140-6, 2007.

- RAJAEI, Amir. MEDICAL IMAGE TEXTURE SEGMENTATION USING RANGE FILTER. 2012.
- RASTGARPOUR, Maryam; SHANBEHZADEH, J. Application of ai techniques in medical image segmentation and novel categorization of available methods and. In: Tools, Proceedings of the International MultiConference of Engineers and Computer Scientists 2011 Vol I, IMECS 2011, March 16-18, 2011, Hong Kong. 2011.
- ROCHA, V.B.D. Uma abordagem de wavelets aplicada à combinação de previsões: uma análise teórica e experimental. Curitiba-PR, 2008, 155 p. Dissertação (Mestrado) – Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná, 2008.
- SAHU, Deepak Kumar; PARSAL, M. P. Different image fusion techniques—a critical review. International Journal of Modern Engineering Research (IJMER), v. 2, n. 5, p. 4298-4301, 2012.
- SAINI, Sujata; ARORA, Komal. A study analysis on the different image segmentation techniques. International Journal of Information & Computation Technology, v. 4, n. 14, p. 1445-1452, 2014.
- SCHIEMANN, Thomas et al. Interpretation of tomographic images using automatic atlas lookup. In: Visualization in Biomedical Computing 1994. International Society for Optics and Photonics, 1994. p. 457-465.
- SCHIEMANN, Thomas; TIEDE, Ulf; HÖHNE, Karl Heinz. Segmentation of the visible human for high-quality volume-based visualization. Medical image analysis, v. 1, n. 4, p. 263-270, 1997.
- SCHIEMANN, Thomas et al. Generation of 3D anatomical atlases using the Visible Human. In: Proc. of SCAR, Symposia Foundation, Carlsbad, CA. 1996. p. 62-67.
- SCURI, Antonio Escaño. Fundamentos da imagem digital. Pontifícia Universidade Católica do Rio de Janeiro, 1999.
- SREEDEVI, E.; PADMAVATHAMMA, M. Design and Development of Hybrid Genetic Classifier Model for Prediction of Diabetes. International Journal of Modern Trends in Engineering and Research, v. 3, p. 260-265, 2016.

- SUETENS, Paul. Fundamentals of medical imaging. Cambridge university press, 2017.
- SIEGA, R. Uma Abordagem 3D para Segmentação do Encéfalo em Imagens de RM. Dissertação de Mestrado. Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná, 2015.
- SPITZER, Victor et al. The visible human male: a technical report. Journal of the American Medical Informatics Association, v. 3, n. 2, p. 118-130, 1996.
- SPITZER, Victor M.; WHITLOCK, David G. The Visible Human Dataset: the anatomical platform for human simulation. The Anatomical Record: An Official Publication of the American Association of Anatomists, v. 253, n. 2, p. 49-57, 1998.
- SRIDHAR, H.; SUBRAMANYA, J. S. P.; KUMAR, J. R. H. A Fully Automated Spinal Cord Segmentation. 978-1-7281-1295-4/18/IEEE, 2018.
- TAMURA, Hideyuki; MORI, Shunji; YAMAWAKI, Takashi. Textural features corresponding to visual perception. IEEE Transactions on Systems, man, and cybernetics, v. 8, n. 6, p. 460-473, 1978.
- TANG, Lei et al. Advanced features of whole body sectioned images: Virtual Chinese Human. Clinical Anatomy, v. 23, n. 5, p. 523-529, 2010.
- TIEDE, Ulf; SCHIEMANN, Thomas; HOHNE, Karl Heinz. High quality rendering of attributed volume data. In: Proceedings Visualization'98 (Cat. No. 98CB36276). IEEE, 1998. p. 255-262.
- TING, S. Registro de Imagens Médicas por Maximização da Informação Mútua. Campinas: Encontro do Departamento de Engenharia da Computação e Automação Industrial, 2002.
- THOMOS, Nikolaos; BOULGOURIS, Nikolaos V.; STRINTZIS, Michael G. Optimized transmission of JPEG2000 streams over wireless channels. IEEE Transactions on image processing, v. 15, n. 1, p. 54-67, 2005.
- TURMERO, P. Wavelets: Concepto y aplicaciones para el análisis de señales. Disponível em: <https://www.monografias.com/trabajos105/wavelets-concepto-y-aplicaciones-analisis->

senales/wavelets-concepto-y-aplicaciones-analisis-senales.shtml. Acessado em: 01 Ago. 2019.

VANNIER, M. W.; YATES, R. E.; WHITESTONE, J. Electronic imaging of the human body. Proc Symp Comput Appl Med Care. 1992;35-9, 1992.

WANGENHEIM, A. V.; MANTELLI, S. Técnicas de segmentação simples de imagens. Seminário Introdução à Visão Computacional. Florianópolis: Universidade Federal de Santa Catarina. 1998, pp.25-34. Disponível em: <http://www.inf.ufsc.br/~visao/segmentos.pdf>. Acessado em: 05 Mar. 2016.

WYAWAHARE, Medha V. et al. Image registration techniques: an overview. International Journal of Signal Processing, Image Processing and Pattern Recognition, v. 2, n. 3, p. 11-28, 2009.

XIA, Yong; LIU, Yixuan; WANG, Kuanquan. Visualization of heart from cryosection image based on a hybrid transfer function. In: 2014 International Conference on Audio, Language and Image Processing. IEEE, 2014. p. 106-109.

YANG, F. et al. Visualization of segmented cardiac anatomy with accelerated rendering method. In: 2009 36th Annual Computers in Cardiology Conference (CinC). IEEE, 2009. p. 789-792.

ZHANG, Shao-Xiang et al. The Chinese Visible Human (CVH) datasets incorporate technical and imaging advances on earlier digital humans. Journal of Anatomy, v. 204, n. 3, p. 165-173, 2004.

ZHENG, Lei et al. Segmentation of muscles for 3D representation of acupoints. In: The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2004. p. 1733-1736.

ZITOVA, Barbara; FLUSSER, Jan. Image registration methods: a survey. Image and vision computing, v. 21, n. 11, p. 977-1000, 2003.