


UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”

FACULDADE DE ENGENHARIA

CAMPUS DE ILHA SOLTEIRA

JEAN VITOR DE PAULO

**SEGMENTAÇÃO DA COLUNA VERTEBRAL HUMANA POR MEIO DO
PROCESSAMENTO DE IMAGENS EXTERNAS DA REGIÃO DORSAL**



Ilha Solteira
2018

JEAN VITOR DE PAULO

**SEGMENTAÇÃO DA COLUNA VERTEBRAL HUMANA POR MEIO DO
PROCESSAMENTO DE IMAGENS EXTERNAS DA REGIÃO DORSAL**

Tese apresentada à Faculdade de Engenharia –
UNESP – Campus de Ilha Solteira como parte
dos requisitos exigidos para obtenção do título
de Doutor em Engenharia Elétrica.

Área de Conhecimento: Automação.

Prof. Dr. Alexandre César Rodrigues da Silva
Orientador

Ilha Solteira

2018

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

P331s Paulo, Jean Vitor de.
Segmentação da coluna vertebral humana por meio do processamento de
imagens externas da região dorsal / Jean Vitor de Paulo. -- Ilha Solteira: [s.n.],
2018
89 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia.
Área de conhecimento: Automação, 2018

Orientador: Alexandre César Rodrigues Da Silva
Inclui bibliografia

1. Processamento de imagens. 2. Imagem médica. 3. Processamento de
sinais. 4. Engenharia biomédica. 5. Visão computacional. 6. Ciência da
Computação.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Segmentação da coluna vertebral humana por meio do processamento de imagens externas da região dorsal

AUTOR: JEAN VÍTOR DE PAULO

ORIENTADOR: ALEXANDRE CESAR RODRIGUES DA SILVA

Aprovado como parte das exigências para obtenção do Título de Doutor em ENGENHARIA ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:



Prof. Dr. ALEXANDRE CESAR RODRIGUES DA SILVA
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira




Prof. Dr. APARECIDO AUGUSTO DE CARVALHO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Profa. Dra. BERENICE CAMARGO DAMASCENO
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. LUCAS FERRARI DE OLIVEIRA
Departamento de Informática / Universidade Federal do Paraná



Prof. Dr. MARCOS AURÉLIO BATISTA
Departamento de Ciência da Computação / Universidade Federal de Goiás - UFG

Ilha Solteira, 02 de março de 2018

A minha família
Dedico

AGRADECIMENTOS

Ao meu orientador Professor Dr. Alexandre César Rodrigues da Silva, pela disponibilidade, auxílio, aconselhamento e por sempre acreditar neste trabalho.

A toda minha família pela empatia e por compartilhar de minhas decisões. Em especial a minha grande inspiração, maior amigo e companheiro, meu pai Roberto de Paulo. A minha madrastra Genilda, meus irmãos Jacqueline e Igor e minha mãe Rita.

Aos meus avós Maria José de Paulo e Nelito Paulo Vitor (*in memoriam*) pela minha criação, inestimáveis ensinamentos e apoio que recebi e continuo a receber.

Ao incalculável auxílio realizado pelo grande amor da minha vida e companheira incondicional, minha esposa Larissa Cruvinel Oliveira.

A amiga Caroline Meireles Fanfoni pelo auxílio em todas as etapas deste trabalho.

A todos os voluntários que se disponibilizaram e forneceram seus dados para esta pesquisa.

A toda equipe da Unidade Básica de Saúde IV de Ilha Solteira - São Paulo por também acreditar neste trabalho e fornecer pessoal, ambiente e equipamentos adequados.

Aos amigos do Laboratório de Processamento de Sinais e Sistemas Digitais: Alexandre Amaral, Willian, Jeferson, Evandro, Douglas e Melisa.

Aos amigos Caroline Barbieri, Uiliam e Ronaldo.

A CAPES e CNPq pelo auxílio financeiro.

A todos que contribuíram indiretamente para a realização deste trabalho.

“Conhecer-se é o começo de toda a sabedoria”

—**Aristóteles**

RESUMO

Neste trabalho avaliou-se a segmentação da coluna vertebral humana utilizando imagens externas da região dorsal. A avaliação foi realizada utilizando imagens de 70 pessoas (58 mulheres e 12 homens). Essas imagens foram agrupadas por meio da associação entre a quantidade de informação existente, dado pelo valor de entropia da imagem e uma avaliação qualitativa de visibilidade da musculatura paravertebral, realizada por três avaliadores. A segmentação foi feita utilizando um algoritmo, chamado DISLo (*Dorsal Image Spine Locator*), que processa imagens da região dorsal baseando-se na informação visível. Após o processamento, o algoritmo DISLo produz uma imagem binária contendo uma linha de pixels de intensidade 255 que representam a coluna vertebral identificada. Aplicando o algoritmo em todas as imagens, obteve-se uma segmentação de mais de 75% da coluna vertebral na maioria dos casos (40 imagens), e na minoria (4 imagens), menos de 25%. Posteriormente, para avaliar a qualidade da segmentação, utilizou-se o RMSD (*Root Mean Square Deviation*) calculado entre os pixels da segmentação automática do DISLo e outra realizada de modo manual, obtida da média de 9 avaliações realizadas por três avaliadores. Pôde-se verificar que as segmentações possuem uma exatidão maior em imagens com mais entropia, bem como possuem uma diferença no RMSD de ± 2 pixels quando comparadas a imagens radiográficas. Portanto, a utilização de imagens externas da região dorsal para identificação da coluna vertebral é viável e apresenta uma maneira confiável para avaliação da mesma.

Palavras-chave: Coluna vertebral. Processamento de imagens. Entropia. RMSD.

ABSTRACT

In this work, the segmentation of the human vertebral column was evaluated using external images of the dorsal region. The evaluation was performed using 70 individual images (58 women and 12 men). These images were grouped using the association between the amount of existing information, given by the entropy value of the image, and a qualitative assessment of the paravertebral musculature visibility, performed by three evaluators. The segmentation was performed using an algorithm called DISLo (Dorsal Image Spine Locator) which processes images from the dorsal region, based on the visible information. After the processing, the DISLo algorithm produces a binary image containing a line with pixels having a 255 intensity value that represents the identified backbone. Applying the algorithm to all images resulted in a segmentation of more than 75% of the spine in most cases (40 images), and in the minority (4 images), less than 25%. Subsequently, to evaluate the quality of the segmentation, the RMSD (Root Mean Square Deviation) was calculated between the pixels of DISLo's automatic segmentation and a manual one, obtained from the average of 9 evaluations performed by three evaluators. It could be verified that the segmentations have a greater accuracy in images with more entropy as well as having a difference in the RMSD of ± 2 pixels when compared to radiographic images. Therefore, the use of external images of the dorsal region for identification of the spine is viable, and a reliable method for its evaluation.

Keywords: Spine. Image processing. Entropy. RMSD.

LISTA DE FIGURAS

Figura 1 – Tipos de vizinhas de pixels.	20
Figura 2 – Operações lógicas entre pixels.	22
Figura 3 – Imagens e seus respectivos histogramas.	23
Figura 4 – Etapas de um sistema de visão artificial.	24
Figura 5 – (A) Imagem original (B) Imagem de magnitude do vetor de gradientes G_{mag} .	27
Figura 6 – Histograma em um processo de limiarização (a) simples e (b) multinível.	28
Figura 7 – Exemplo de limiarização normal e multinível.	29
Figura 8 – (A) Imagem com entropia de 2,88 e (B) Imagem com entropia de 0,59.	30
Figura 9 – Estrutura de funcionamento da biblioteca OpenCV.	31
Figura 10 – Código para exibir uma imagem em C++ com OpenCV.	32
Figura 11 – Janela produzida pelo algoritmo.	33
Figura 12 – Sistema ósseo visto no plano posterior.	34
Figura 13 – Composição de uma vértebra cervical.	35
Figura 14 – Composição de uma vértebra torácica.	35
Figura 15 – Composição de uma vertebra lombar.	36
Figura 16 – Músculos do grupo superficial.	37
Figura 17 – Camada média dos músculos dorsais.	38
Figura 18 – Músculos eretores da espinha do grupo profundo.	40
Figura 19 – Músculos transverso-espinhais e segmentares do grupo profundo.	42
Figura 20 – Extensão da coluna vertebral e suas curvaturas.	43
Figura 21 – Medula espinhal e suas adjacências.	44
Figura 22 – Anatomia de superfície do dorso.	45

Figura 23 – Região dorsal externa com destaque à coluna vertebral.	45
Figura 24 – Saída visual dos algoritmos EBM e LPREM.	47
Figura 25 – Esquema de medição utilizando triangularização a laser.	48
Figura 26 – Imagens intermediárias da segmentação utilizando laser.	49
Figura 27 – Segmentação completa utilizando o <i>framework</i> .	50
Figura 28 – Avaliação topográfica da região dorsal.	50
Figura 29 – Avaliação de um paciente com o dispositivo Spinal Mouse®.	51
Figura 30 – Etapas de execução do algoritmo DISLo.	53
Figura 31 – A) Imagem inicial, B) entrada ideal para o algoritmo.	54
Figura 32 – Recorte da região dorsal em tom de cinza com histograma equalizado.	54
Figura 33 – Algoritmo responsável pelo cálculo da ocorrência de cada nível de cinza.	55
Figura 34 – Algoritmo para cálculo de entropia.	56
Figura 35 – Imagem filtrada bilateralmente.	57
Figura 36 – Imagem após a aplicação do filtro Prewitt estendido.	58
Figura 37 – Composição parcial.	59
Figura 38 – Exemplo de seleção de contornos.	59
Figura 39 – Algoritmo para cálculo dos pontos extremos à esquerda e direita.	60
Figura 40 – A) Regiões em excesso selecionadas B) Regiões removidas.	62
Figura 41 – Ligamento de regiões.	63
Figura 42 – Imagem com falhas de preenchimento.	63
Figura 43 – Algoritmo para preenchimento de região.	64
Figura 44 – Imagem com regiões preenchidas.	65
Figura 45 – Imagens do fim do processo de afinamento.	65
Figura 46 – Imagem ao fim do processo de afinamento.	66
Figura 47 – Imagens de entrada e seus respectivas RVEs obtidas pelo algoritmo DISLo.	67

Figura 48 – Exemplo de uma imagem adquirida pelo método apresentado.	69
Figura 49 – Imagem contendo exemplos de classificação.	71
Figura 50 – Valores qualitativos do avaliador A_1 .	71
Figura 51 – Valores qualitativos do avaliador A_2 .	72
Figura 52 – Valores qualitativos do avaliador A_3 .	72
Figura 53 – Grupos de avaliação após a média das avaliações de A_1 , A_2 e A_3 .	73
Figura 54 – Associação entre entropia e avaliação qualitativa.	74
Figura 55 – Proporção total em relação ao tamanho da imagem.	76
Figura 56 – Exemplos de imagens segmentadas manualmente.	77
Figura 57 – (A) Imagem intermediária contendo o somatório de todas as segmentações (B) Imagem $\overline{M}$ (C) Sobreposição de $\overline{M}$ e imagem original.	78
Figura 58 – Algoritmo para extração da segmentação automática e manual.	79
Figura 59 – Correlação entre a porcentagem identificada e o RMSD de cada imagem.	80
Figura 60 – (a) Radiografia com marcações em vermelho próximo ao centro de cada corpo vertebral, (b) RVE equivalente.	81
Figura 61 – Associação entre os valores RMSD das radiografias avaliadas e da entropia de suas respectivas imagens dorsais.	82

LISTA DE TABELAS

Tabela 1 – Dados dos grupos quando associadas à $H(x)$.	74
Tabela 2 – Valores de entropia e seus respectivos grupos qualitativos.	75
Tabela 3 – Proporção da identificação de acordo com os grupos.	76
Tabela 4 – Grupos entrópicos e suas características.	79
Tabela 5 – Valores de RMSD obtidos utilizando a RVE equivalente da imagem radiográfica.	82
Tabela 6 – Grupos entrópicos das imagens dorsais das radiografias e seus respectivos RMSD médios.	83

LISTA DE ABREVIATURAS E SIGLAS

CV	Coeficiente de Variação
DISLo	Dorsal Image Spine Locator
EBM	Entropy Based Masking
HDR	High Dynamic Range
LPREM	Low-Pixel Resolution Entropy-Based Masking
MI	Momentos Invariantes
ML	<i>Machine Learning</i>
PC	Ponto de corte
REQM	Raiz do Erro Quadrático Médio
RMSD	<i>Root Mean Square Deviation</i>
RMSE	<i>Root Mean Square Error</i>
RVE	Representação Visual Externa

SUMÁRIO

1	INTRODUÇÃO	17
2	PROCESSAMENTO DE IMAGENS	19
2.1	DISCRETIZAÇÃO ESPACIAL E DE AMPLITUDE	19
2.2	RELAÇÕES ENTRE PIXELS	20
2.2.1	Vizinhança	20
2.3	CONECTIVIDADE	20
2.4	MANIPULAÇÃO ARITMÉTICA E LÓGICA	21
2.5	ADJACÊNCIA	22
2.6	HISTOGRAMA	22
2.7	SISTEMAS DE VISÃO ARTIFICIAL	23
2.8	EXTRAÇÃO DE INFORMAÇÕES	25
2.9	DETECÇÃO DE BORDAS	25
2.9.1	Detecção baseada em máscaras e filtragem espacial	26
2.9.2	Limiarização	27
2.10	TEORIA DA INFORMAÇÃO E IMAGENS	29
2.10.1	Entropia de Shannon	29
2.10.2	Aplicação da entropia no processamento de imagens	30
2.11	OPENCV	30
2.11.1	Funcionalidades	31

3	REGIÃO DORSAL HUMANA	34
3.1	SISTEMA ÓSSEO	34
3.2	MUSCULATURA	36
3.2.1	Grupo superficial	36
3.2.1.1	<i>Trapézio</i>	37
3.2.1.2	<i>Latíssimo do dorso</i>	37
3.2.1.3	<i>Levantador da escápula</i>	38
3.2.1.4	<i>Romboides menor e maior</i>	38
3.2.2	Grupo médio	38
3.2.2.1	<i>Serrátil posterior superior e inferior</i>	39
3.2.3	Grupo profundo	39
3.2.3.1	<i>Aponeurose toracolombar</i>	39
3.2.3.2	<i>Músculos eretores da espinha</i>	39
3.2.3.3	<i>Músculos espinotransversais</i>	40
3.2.3.4	<i>Músculos transverso-espinais</i>	41
3.2.3.5	<i>Músculos segmentares</i>	41
3.2.3.6	<i>Músculos suboccipitais</i>	41
3.3	FUNCIONALIDADES	42
3.3.1	Sustentação	42
3.3.2	Movimentação	43
3.3.3	Proteção	44
3.4	ANATOMIA DE SUPERFÍCIE DA REGIÃO DORSAL	44
4	REVISÃO DA LITERATURA	47

5	DISLo (DORSAL IMAGE SPINE LOCATOR)	53
5.1	ETAPAS DO ALGORITMO DISLo	53
5.1.1	Entrada	53
5.1.2	Pré-processamento	54
5.1.2.1	<i>Cálculo da entropia</i>	55
5.1.3	Filtragem e separação	56
5.1.3.1	<i>Filtro bilateral</i>	56
5.1.3.2	<i>Detecção de bordas</i>	57
5.1.3.3	<i>Limiarização</i>	58
5.1.3.4	<i>Seleção de contornos</i>	59
5.1.4	Parametrização	60
5.1.4.1	<i>Pontos extremos</i>	60
5.1.4.2	<i>Parâmetros adicionais</i>	61
5.1.5	Aprimoramento	61
5.1.5.1	<i>Remoção de excessos</i>	61
5.1.5.2	<i>Ligamento de regiões de acordo com o centro de massa</i>	62
5.1.5.3	<i>Preenchimento de região</i>	63
5.1.5.4	<i>Afinamento</i>	65
5.1.5.5	<i>Remoção de ruídos</i>	66
6	AVALIAÇÃO DAS IMAGENS	68
6.1	IMAGENS UTILIZADAS	68
6.1.1	Metodologia de aquisição	68
6.2	METODOLOGIA DE AVALIAÇÃO	69

6.3	AVALIAÇÃO QUALITATIVA	70
6.4	ASSOCIAÇÃO ENTRE AVALIAÇÃO QUALITATIVA E ENTROPIA	73
6.5	AVALIAÇÃO DA RVE	75
6.6	SEGMENTAÇÃO MANUAL E COMPARAÇÃO COM AS RVE'S	77
6.6.1	Extração e imagem média	77
6.7	COMPARAÇÃO DOS MÉTODOS MANUAL E AUTOMÁTICO	78
6.8	COMPARAÇÃO DAS RVE'S COM IMAGENS RADIOGRÁFICAS	80
6.8.1	Comparação com imagens radiográficas	80
6.8.2	Comparação com as respectivas RVE's	81
7	CONCLUSÕES	84
7.1	TRABALHOS FUTUROS	85
	REFERÊNCIAS	86

1 INTRODUÇÃO

As imagens digitais possuem características que as habilitam ser matematicamente representadas a partir de uma matriz numérica com a disposição de seus pixels. Com isso, é possível que propriedades de sua estrutura sejam identificadas por meio de algoritmos e operações matemáticas. Dessa forma, o processamento de imagens fornece métodos para sintetizar dados de uma determinada região de uma cena, visando extrair informações para um processo ao qual se destinam.

A estrutura musculoesquelética humana possui características organizacionais que permitem que certas estruturas internas sejam visualizadas externamente. A região dorsal, especificamente, possui uma disposição osteomuscular em que determinados músculos se encontram adjacentes à coluna vertebral. Devido a essa organização, alterações no relevo da região ocorrem, criando externamente um contorno em que a coluna vertebral pode ser visualmente identificada (LUMLEY, 2008).

O estudo do alinhamento da coluna vertebral constantemente cria maneiras de avaliação e métodos para monitorar e controlar deformações, devido a possibilidade de diminuir uma provável exposição do paciente a exames contendo radiação ionizante (SMITH et al., 2017). Essa categoria de exames, que é amplamente utilizada na avaliação dessa região, está diretamente correlacionada ao desenvolvimento de câncer, além de se mostrar prejudicial a longo prazo (RONCKERS et al., 2008), o que dificulta a avaliação progressiva e constante do paciente (GARGANI; PICANO, 2015). Visto que, um diagnóstico rápido e o acompanhamento contínuo se mostra necessário para diversos tipos de deformidades da coluna vertebral (ASHER; BURTON, 2006).

Em consequência, recomenda-se que os profissionais de saúde evitem sempre que possível, expor pacientes a exames que contenham radiação ionizante. Essa abordagem pode ser alcançada com a utilização de exames não-invasivos que possuam precisão semelhante (PICANO et al., 2014).

Os métodos não-invasivos comumente necessitam de um conjunto específico de

câmeras, equipamento especializado e uma metodologia rigorosa de avaliação. Também é ainda comum que os equipamentos sejam constantemente recalibrados, readaptados e tenham determinados parâmetros exclusivos para cada pessoa avaliada (SELBY et al., 2011; O'CALLAGHAN et al., 2014).

Com as alterações de tonalidade que a musculatura paravertebral provoca na pele, uma foto da região obtida com uma câmera digital convencional pode fornecer dados importantes quando processadas adequadamente. Com isso, este trabalho teve como objetivo avaliar a segmentação da coluna vertebral utilizando unicamente uma imagem da região dorsal. A segmentação foi realizada automaticamente com um algoritmo desenvolvido para este fim, chamado DISLo. Foram avaliadas segmentações de 70 imagens, separadas em grupos de acordo com seu valor de entropia. A qualidade da segmentação foi avaliada de acordo com sua proporção e exatidão quando comparada com uma segmentação realizada manualmente e com imagens radiográficas, fornecidas por 9 voluntários.

Este trabalho contribui com a realização de exames sem a necessidade de um equipamento específico e complexo, apresentando que imagens dorsais externas podem fornecer informações relevantes ao profissional de saúde, auxiliando em sua tomada de decisão. O que tende a diminuir o custo e tornar a obtenção de diagnósticos mais rápida.

O estudo é exposto em 7 capítulos. No capítulo 2 são apresentados conceitos essenciais para o entendimento de processamento de imagens. No terceiro capítulo, é abordada a anatomia humana com ênfase na região dorsal. No capítulo 4, uma revisão bibliográfica de estudos relacionados é realizada. No capítulo 5, são apresentados os procedimentos utilizados na programação, bem como um passo a passo da execução do algoritmo DISLo. No capítulo 6, são expostos os resultados obtidos na avaliação das imagens dos voluntários. As considerações finais e trabalhos futuros podem ser vistos no capítulo 7.

2 PROCESSAMENTO DE IMAGENS

O processamento de imagens tem como principal fundamento a consideração de uma figura como uma estrutura representada numericamente em forma de matriz. Logo, diversos conceitos sobre a composição de uma imagem necessitam ser compreendidos para que a mesma seja adequadamente processada. Estes conceitos são descritos neste capítulo, bem como a fundamentação matemática utilizada para avaliação dos resultados apresentados posteriormente.

2.1 DISCRETIZAÇÃO ESPACIAL E DE AMPLITUDE

Uma imagem, obtida por um sistema de aquisição, necessita ser submetida a processos de digitalização para que possa ser manipulada computacionalmente. Os procedimentos realizados são dois: digitalização das coordenadas espaciais (x, y) , que é chamado de amostragem, e de amplitude, chamado quantização (GONZALES; WOODS, 2011). Na amostragem, uma imagem é convertida em uma matriz de dimensões $N \times M$, igualmente espaçadas, em que cada posição é considerada um pixel, conforme descrito na Equação 1.

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

A quantização faz com que cada uma dessas posições assumam um valor pertencente ao intervalo de 0 a $2^n - 1$, para imagens monocromáticas. Quanto maiores forem os valores M , N e n , maior será o custo de armazenamento da imagem e, conseqüentemente, o grau de detalhes discerníveis. Isso faz com que a matriz digitalizável seja mais próxima à imagem original. Entretanto, o conceito de qualidade de imagem é algo subjetivo e dependente da aplicação em que a imagem será utilizada.

2.2 RELAÇÕES ENTRE PIXELS


Considerando que uma imagem digital é uma função $f(x, y)$ amostrada, quantizada e matricialmente representada, pode-se definir relacionamentos entre seus pixels.

2.2.1 Vizinhaça

Para cada pixel p , em sua coordenada (x, y) existem pixels que formam o que pode ser considerado sua vizinhaça, comumente dividida em três.

- Vizinhaça diagonal: são os elementos $(x - 1, y - 1)$, $(x - 1, y + 1)$, $(x + 1, y - 1)$ e $(x + 1, y + 1)$ referentes ao pixel p e formam o conjunto $N_d(p)$;
- 4-Vizinhaça: imediações do pixel p presente na horizontal e vertical. São representados pelas coordenadas $(x + 1, y)$, $(x - 1, y)$, $(x, y + 1)$ e $(x, y - 1)$. Simplificadamente, pode ser definida por $N_4(p)$;
- 8-Vizinhaça: a união da 4-vizinhaça com a vizinhaça diagonal forma a 8-vizinhaça, ou ainda, $N_8(p)$, conforme pode ser visto na Figura 1.

Figura 1 – Tipos de vizinhas de pixels.



Fonte: Autoria própria.

2.3 CONECTIVIDADE

A conexão entre pixels de uma imagem é dependente de sua vizinhaça, logo, somente pixels adjacentes definidos por um critério escolhido, podem ser considerados conectados. Esse critério é variável e é arbitrariamente definido. A conectividade é efetivada quando os vizinhos de um determinado pixel possuem níveis de cinza similares, também seguindo um critério pré-estabelecido (PETROU; PETROU, 2010).


- 4-conectividade: quando p e q estiverem em um mesmo conjunto de níveis de cinza, eles serão conectados se o critério de similaridade for atendido e q estiver contido em $N_4(p)$;
- 8-conectividade: p e q são 8-conectados se o critério de similaridade dos níveis for atendido e q estiver contido em $N_8(p)$;
- m-conectividade: uma variação da 8-conectividade no qual p e q necessitam atender o critério de similaridade de níveis de cinza, bem como atender uma das duas seguintes possibilidades:
 1. q estiver contido em $N_4(p)$;
 2. q estiver contido em $N_d(p)$ e $N_4(p)$ não apresentar nenhum pixel em comum com $N_4(q)$.

2.4 MANIPULAÇÃO ARITMÉTICA E LÓGICA

Uma imagem digitalizada, construída por meio de uma matriz numérica, pode ser alterada utilizando operações aritméticas e lógicas. Essa manipulação pode ser realizada pixel a pixel ou orientada à vizinhança. Exemplos de usos das operações lógico-aritméticas são:

- Adição: utilizada para obter médias de imagens para redução de ruído;
- Subtração: destaca-se em imagens médicas em que são necessários procedimentos para retirar informações estáticas de determinados locais da imagem;
- Multiplicação e divisão: correção de sombras produzidas por não-uniformidades da iluminação.

As operações lógicas *AND*, *OR* e *NOT* também podem ser aplicadas em imagens, com a exigência de que a matriz contenha apenas valores binários. Na Figura 2, apresentam-se as operações lógicas.

Figura 2 – Operações lógicas entre pixels.**Fonte:** Autoria própria.

2.5 ADJACÊNCIA


Se os pixels p e q de uma imagem estiverem conectados, eles também são adjacentes. Logo, dois conjuntos são considerados adjacentes caso existir algum pixel conectando-os (GONZALES; WOODS, 2011). Tal como os conceitos de conectividade e vizinhança, também existem 4-adjacência, 8-adjacência e m-adjacência de acordo com sua conectividade.

2.6 HISTOGRAMA

Um histograma é a representação visual em um gráfico da distribuição dos pixels de uma imagem, de acordo com seu nível de intensidade.

O histograma permite visualizar características da imagem, como os níveis de contraste e o brilho médio. Uma imagem com baixo nível de detalhe tem níveis de cinza concentrados em apenas um local, já uma imagem com maior nível de detalhe, possui uma distribuição esparsa. Exemplos de histograma podem ser vistos na Figura 3.

Figura 3 – Imagens e seus respectivos histogramas.



Fonte: Autoria própria.


Conforme pode ser visualizado, a Figura 3 (A), que possui um nível de detalhe maior, tem em seu histograma um conjunto de níveis de cinza mais esparso, sendo a maioria dos pixels distribuídos na porção que representa os pixels mais escuros. A Figura 3 (C), possui um nível de discernimento de detalhes menor e tem seu histograma com os pixels representados mais próximos ao valor máximo de nível de intensidade do gráfico.

2.7 SISTEMAS DE VISÃO ARTIFICIAL

O sistema de visão artificial é um conjunto de processos em que os procedimentos de adquirir, processar e interpretar imagens correspondentes a cenas reais são executados para a resolução de um problema (MARQUES FILHO; VIEIRA NETO, 1999).

Comumente, um sistema de visão artificial é descrito por meio das etapas apresentadas na Figura 4.

Figura 4 – Etapas de um sistema de visão artificial.



Fonte: Autoria própria.

- **Aquisição:** a primeira etapa consiste na obtenção da imagem utilizando um dispositivo apropriado que contenha um sensor, para conversão do sinal ótico em elétrico, e um digitalizador, para decompor esse sinal proveniente do sensor;
- **Pré-processamento:** passo responsável pela redução de aspectos inadequados da imagem adquirida, como pixels com ruído ou brilho e contraste alterados, preparando a imagem para as etapas subsequentes;
- **Segmentação:** é o procedimento de divisão da imagem em locais de interesse, destacando ou adequando o local em questão para visualização ou demais manipulações;
- **Extração de características:** a imagem resultante da segmentação fornece informações a essa etapa, que é responsável pela caracterização de regiões da imagem que forem adequadas ao processo em execução. A entrada desse passo é uma imagem e a saída é uma estrutura de dados apropriada ao Reconhecimento e Interpretação;
- **Reconhecimento e Interpretação:** a última fase é a atribuição de um rótulo a uma área baseado nas características reconhecidas pelo passo anterior. A interpretação

consiste em atribuir significado aos rótulos reconhecidos;

- Base de conhecimento: as atividades descritas necessitam de um conhecimento prévio já estabelecido e armazenado em uma base de dados. O objetivo da Base de Conhecimento, idealmente, é de conduzir cada etapa e permitir a realimentação entre elas, apontando erros ou demandando que a tarefa anterior seja executada de maneira diferente.

2.8 EXTRAÇÃO DE INFORMAÇÕES

De acordo com Petrou e Petrou (2010), a segmentação e detecção de bordas tem por objetivo extrair informação de uma imagem gerando uma figura secundária com menos informações que a original. Contudo, o conteúdo será consideravelmente mais relevante ao processo do que o original.

Os algoritmos para essa tarefa em imagens monocromáticas, baseiam-se nos conceitos de similaridades e descontinuidade. Normalmente, pixels com características semelhantes como cor ou brilho, indicam que pertencem ao mesmo objeto de uma cena. Petrou e Petrou (2010) evidenciam que também existem técnicas para segmentação de regiões que não possuem níveis de cinza constantes, mas são percebidas visualmente como uniformes. Para isso, os pixels não podem ser caracterizados pelo nível de cinza, mas sim pela taxa de variação que quantifica a alteração dos valores de cinza ao redor de um determinado ponto.

Considerando essa abordagem, o problema só é solucionado com a atribuição de diversos valores a um determinado segmento da imagem. Assim, todo pixel assume um vetor com diversos valores, cada um representando uma característica de sua região. Pixels pertencentes a mesma região terão valores semelhantes ou idênticos em seus atributos sendo então, agrupados.

2.9 DETECÇÃO DE BORDAS

Considerando uma imagem em tons de cinza, de acordo com Gonzales e Woods (2011), bordas são limites entre duas regiões com tonalidades relativamente distintas. Usualmente, bordas representam o contorno de algum objeto ou região na imagem.

Parker (2010) afirma que esses contornos representam informações importantes para a Visão Computacional devido à sua correlação com locais de interesse na imagem. Se os locais de interesse podem ser detectados, então é possível identificar objetos e regiões na

cena.

A detecção de bordas é uma etapa do processamento que retira informação da imagem que idealmente não pertence a nenhuma descontinuidade de nível de luminosidade, tornando-a assim, mais adequada para uma etapa de extração de características.

Uma borda ideal é aquela em que ocorre uma variação repentina de tonalidade, conhecida como Borda Degrau. Existe também como outra alteração ideal, a Borda Linha, que é aquela em que o nível de cinza após atingir um máximo, retorna ao seu valor inicial. Contudo, esses perfis raramente ocorrem em uma situação real, que comumente assume a forma triangular, ou de rampa.

De acordo com Parker (2010), existem dois problemas que prejudicam a identificação ideal das bordas por um algoritmo, sendo eles:

- Digitalização: durante esse processo, eventualmente a imagem terá pixels amostrados de maneira que não corresponderão precisamente às bordas, o que pode se estender por diversas regiões da imagem;
- Ruído: diversos fatores podem provocar ruídos e prejudicar a identificação de bordas. Com a incidência de ruídos, torna-se improvável que uma tonalidade de iluminação na imagem seja exatamente correspondente ao seu equivalente digitalizado.

2.9.1 Detecção baseada em máscaras e filtragem espacial

Uma máscara é um operador discreto, matricial, que é utilizado no domínio do espaço e aplicado a uma imagem como método de se destacar ou eliminar determinadas características. O funcionamento desse tipo de filtragem é baseado nas variações de um pixel e sua vizinhança.

Quando utilizado na detecção de bordas, um determinado filtro é aplicado em uma imagem por meio da operação de convolução, criando em seguida uma imagem de saída que é a aproximação do vetor gradiente.

São visualizadas nas Equação 2 e 3 duas máscaras Prewitt (1970): Gx para detecção do gradiente vertical e Gy para o eixo horizontal.

$$Gx = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad (2)$$

$$G_y = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad (3)$$


Outros exemplos de máscaras disponíveis são Roberts (ROBERTS, 1963) e Sobel (DUDA; HART, 1973). Suas diferenças são os valores contidos na matriz utilizada na obtenção dos gradientes. Essa diferença altera os gradientes G_y e G_x , gerando uma resposta diferente das bordas contidas na imagem

A detecção das bordas é realizada após a aplicação da Equação 4, gerando uma imagem contendo a magnitude aproximada do vetor de gradientes.

$$G_{mag} = \sqrt{(G_x)^2 + (G_y)^2} \quad (4)$$

Na Figura 5 pode-se visualizar um exemplo de uma imagem G_{mag} .

Figura 5 – (A) Imagem original (B) Imagem de magnitude do vetor de gradientes G_{mag} .



Fonte: Autoria própria.

2.9.2 Limiarização

É uma técnica de segmentação que busca com a análise dos níveis de cinza de uma imagem, separá-los conforme necessário. Considerando objetos em uma cena, após a análise de seus níveis de cinza, é possível segmentá-los utilizando-se um limiar T . Esse limiar será responsável pela divisão dos pixels em grupos, um abaixo desse limiar e outro, acima.

Uma imagem limiarizada assume valores de pixels iguais para todo um grupo,

conforme Equação 5.

$$G(x) = \begin{cases} 1, & \text{se } f(x, y) \geq T \\ 0, & \text{se } f(x, y) < T \end{cases} \quad (5)$$

É possível também, realizar uma limiarização com mais de dois conjuntos, chamada limiarização multinível. Esse procedimento é realizado através da definição de diversos intervalos, com $T_1 < f(x, y) \leq T_2$, no qual T_1 e T_2 são níveis de cinza.

Considerando uma imagem em que um objeto claro está posicionado sobre um fundo escuro, o histograma dessa imagem terá dois picos: um representando o fundo escuro e outro representando o objeto. Utilizando a limiarização simples, pode-se selecionar um ponto no meio do vale, que existirá entre os dois picos, indicando que todos os pixels à sua direita são referentes ao objeto, e à esquerda, o fundo. Ou ainda pode-se utilizar a limiarização multinível e escolher um intervalo melhor definido. Na Figura 6 são apresentados dois histogramas que representam a limiarização com um e dois limiares.


Figura 6 – Histograma em um processo de limiarização (a) simples e (b) multinível.



Fonte: Petrou e Petrou (2010).

Na Figura 7 apresenta-se um processo de limiarização utilizando ambos os conceitos.

Figura 7 – Exemplo de limiarização normal e multinível.



Fonte: Petrou e Petrou (2010).

2.10 TEORIA DA INFORMAÇÃO E IMAGENS

A teoria da informação é um campo que teve início com o trabalho realizado por Shannon (1948). Nesse trabalho é discutido que considerando um ponto de origem, uma mensagem teria que ser reproduzida exatamente ou o mais fiel possível no ponto de destino. Para tal, desconsidera-se os aspectos semânticos da mensagem, sendo a mesma então tratada como uma coleção de símbolos discretos. Logo, a quantidade de informação desse sistema está ligada à variabilidade dos símbolos da mensagem.

2.10.1 Entropia de Shannon

Considerando uma variável discreta aleatória x que possui uma distribuição probabilística $p_x = (p_1, \dots, p_n)$, a sua quantidade de informação é dada pelo valor de entropia como definido por Shannon (1948). O valor entrópico $H(x)$ pode ser calculado pela seguinte equação:

$$H(x) = - \sum_{i=1}^n p_i \log_2 p_i \quad (6)$$

2.10.2 Aplicação da entropia no processamento de imagens

Quando aplicado a imagens, considera-se n como sendo o número máximo de tonalidades e p_i a probabilidade de um determinado símbolo (pixel) ocorrer. Dessa forma, tem-se $p_i = R_i/S$ em que R_i é o valor de tonalidade do pixel atual e S a quantidade total de pixels.

Com isso, baixo contraste e baixa variação de tonalidade determina uma imagem com pouca informação e uma alta organização, logo, sua resposta entrópica $H(x)$, tende a 0. Em contraponto, imagens com alto valor de contraste e alta variação dos pixels tendem a apresentar uma resposta que pode chegar a $H(x)_{Max} = \log_2(n)$. Na Figura 8 são apresentadas duas imagens distintas, com seus respectivos valores de entropia.

Figura 8 – (A) Imagem com entropia de 2,88 e (B) Imagem com entropia de 0,59.



Fonte: Autoria própria.

Devido ao valor de entropia $H(x)$ da Figura 8 (A) ser maior que a Figura 8 (B), pode-se dizer que a Figura 8 (A) possui uma maior quantidade de informação que a Figura 8 (B).

Bibliotecas de Processamento de Imagens e Visão Computacional que acessam diretamente os pixels de uma imagem e manipula-os, podem ser utilizadas para obter o valor de entropia de uma imagem, bem como aplicar os conceitos expostos neste capítulo.

2.11 OPENCV

O OpenCV é uma biblioteca de visão computacional de código aberto que teve seu desenvolvimento iniciado pela empresa Intel em 1999. É escrita em linguagem C e C++ e pode ser utilizada em sistemas operacionais Linux, Windows, Mac OS, iOS e Android. Possui interfaces com linguagens como Python, Java, Matlab e Ruby. Atualmente,


encontra-se na versão 3.4 (OPENCV, 2017).

Seu uso abrange uma série de aplicações por conter funções para processamento de imagens médicas, interface de usuário, segurança, aprendizado de máquina, calibração de câmera e inspeção industrial de produtos.

2.11.1 Funcionalidades

As funcionalidades do OpenCV estão inseridas em módulos secundários, que são dependentes de um núcleo, chamado de *CORE*. A estrutura de funcionamento do OpenCV e seus principais módulos, pode ser visualizada na Figura 9

Figura 9 – Estrutura de funcionamento da biblioteca OpenCV.



Fonte: Autoria própria.

Os módulos fornecem as seguintes funcionalidades, de acordo com Bradski e Kaehler (2008):

- Core: possui todos os dados primários que definem as estruturas de dados básicas da biblioteca, fornecendo manipulação a nível de pixel;
- Imgproc: é responsável pelo processamento das imagens. Possui funcionalidades que incluem filtros lineares e não lineares, transformadas geométricas de imagens, funções de histograma, conversão de cores e outras;
- Video: módulo de análise de vídeo com avaliação de movimento, extração de plano de fundo e rastreamento de objetos;
- Objdetect: detecção de objetos utilizando classificadores, como Cascata e Máquinas Vetoriais de Suporte;

- Calib3d: algoritmos multi-visão geométrica, calibração de câmera, estimativa de pose e elementos para reconstrução 3d;
- Features2d: detectores de características, descritores e verificações de correspondências desses descritores;
- Photo: utiliza conceitos de fotografia computacional que permitem realizar manipulações em fotos, como aplicação de HDR e outras manipulações de cor;
- Highgui: contém as funções de manipulação de interface de usuário e entrada e saída de vídeo. É capaz de criar janelas, adicionar funções as mesmas e realizar escrita e leitura de arquivos de imagem;
- Ml: módulo para aprendizado de máquina para a classificação estatística, regressão e agrupamento de dados;
- CUDA: contém algoritmos para processamento de vídeo e imagens otimizados para execução diretamente em placas de vídeo da fabricante NVIDIA;

Um código na linguagem de programação C++ para leitura e exibição de uma imagem utilizando os componentes do OpenCV pode ser visualizado na Figura 10.

Figura 10 – Código para exibir uma imagem em C++ com OpenCV.

```

1  #include <opencv2/core.hpp>
2  #include <opencv2/highgui.hpp>
3  #include <iostream>
4
5  using namespace cv;
6  int main(int argc, char** argv) {
7      Mat imagemExemplo = imread("imagem.jpg", CV_LOAD_IMAGE_COLOR);
8      if(imagemExemplo.empty()) {
9          std::cout << "Erro" << std::endl;
10         return 0;
11     }
12     namedWindow("Imagem exemplo");
13     imshow("Imagem exemplo", imagemExemplo);
14     waitKey(0);
15 }

```

Fonte: Autoria própria.

O comportamento do código pode ser descrito linha-a-linha pelos seguintes passos:

- Linhas 1 a 3: insere a utilização do núcleo da biblioteca e das funções responsáveis pela exibição de informações;
- Linha 5: habilita a utilização do *namespace* padrão do OpenCV, onde estão contidas suas funções;

- Linha 7: utiliza a estrutura padrão de representação de imagem em formato matricial *Mat* para carregar uma imagem por meio da função *imread()*;
- Linha 8 a 10: realiza uma verificação se a imagem foi carregada corretamente, abortando o programa caso ocorra um erro;
- Linha 12: cria uma janela intitulada “Imagem exemplo”;
- Linha 13: exibe a janela “Imagem exemplo” criada na linha 12, contendo a imagem carregada.

Considerando o arquivo “imagem.jpg” contendo uma foto da Caixa d’Água de Ilha Solteira - SP, a saída desse algoritmo, quando executado no sistema operacional Linux Ubuntu 16.04 pode ser visualizada na Figura 11.

Figura 11 – Janela produzida pelo algoritmo.



Fonte: Autoria própria.

No próximo capítulo são apresentados conceitos essenciais da anatomia da região dorsal, que em conjunto com o conteúdo apresentado neste capítulo, é fundamental para entendimento de como a segmentação é realizada no algoritmo DISLo.


3 REGIÃO DORSAL HUMANA

Neste capítulo é apresentado a estrutura dorsal humana com ênfase em suas características e agrupamentos osteomusculares. Também é exposto como essas estruturas são visualizadas externamente, utilizando-se de conceitos de anatomia de superfície da região.

3.1 SISTEMA ÓSSEO

Os principais ossos dorsais são as 33 vértebras das quais 7 são cervicais, 12 torácicas, 5 lombares, 5 sacrais e as vértebras coccígeas que são fundidas e possuem quantidade variável e formam o sacro. Na Figura 12 exibe-se o sistema ósseo da coluna vertebral (DRAKE; VOGL; MITCHELL, 2015).

Figura 12 – Sistema ósseo visto no plano posterior.




Fonte: Drake, Vogl e Mitchell (2015).

De acordo com Drake, Vogl e Mitchell (2015), uma vértebra típica consiste de um corpo vertebral e um arco vertebral posterior. O corpo vertebral é responsável pela

sustentação da vértebra e está interconectado com as vértebras adjacentes por meio de discos intravertebrais e ligamentos. São presentes também processos para fixação muscular e articulação com outras estruturas ósseas adjacentes.

As 7 vértebras cervicais são caracterizadas por seu tamanho pequeno e pela presença de aberturas para passagem de nervos e vasos, chamados Forames, em seus processos transversos, que são pontos em que ocorre uma ligação com músculos e ligamentos. Na Figura 13 exibe-se a composição de uma vértebra cervical.

Figura 13 – Composição de uma vértebra cervical.



Fonte: Drake, Vogl e Mitchell (2015).

As vértebras torácicas possuem costelas articuladas, que interagem por meio de articulações sinoviais com os corpos vertebrais e processos transversos das vértebras associadas. Pode-se visualizar essas características na Figura 14.


Figura 14 – Composição de uma vértebra torácica.



Fonte: Drake, Vogl e Mitchell (2015).

As vértebras lombares são caracterizadas por serem maiores, bem como responsáveis por prover a sustentação esquelética para a região da parede abdominal posterior. Na Figura 15 exibe-se uma vértebra lombar.

Figura 15 – Composição de uma vertebra lombar.



Fonte: Drake, Vogl e Mitchell (2015).

Após as vértebras lombares, estão as vértebras sacrais fundidas em um único osso chamado sacro, que se articula em ambos os lados com ossos do quadril e é componente da região pélvica.

Ao fim da coluna, existem as vértebras coccígeas que são unidas em uma única estrutura chamada cóccix. Essas possuem um número que pode variar entre 1 a 4 vértebras (DRAKE; VOGL; MITCHELL, 2015).


3.2 MUSCULATURA

A musculatura da região dorsal humana pode ser dividida levando em consideração o posicionamento dos músculos regionais. Dessa forma, considera-se três regiões: grupo superficial, médio e profundo.

3.2.1 Grupo superficial

O grupo superficial é a porção em que a musculatura encontra-se diretamente após a pele e os demais componentes fibrosos de fixação. Seus músculos são responsáveis pelo movimento dos membros superiores, atuando diretamente sobre a sustentação do corpo (DRAKE; VOGL; MITCHELL, 2015). Pode-se visualizar esse grupo muscular na Figura 16.

Figura 16 – Músculos do grupo superficial.



Fonte: Drake, Vogl e Mitchell (2015).

3.2.1.1 *Trapézio*

O trapézio é o músculo que se encontra mais superficialmente na estrutura dorsal humana. Seu nome provém da união do lado direito e esquerdo, que juntos possuem um formato de trapezoide. A funcionalidade motora é direcionada à elevação dos membros superiores acima da cabeça, atuando diretamente sobre a escápula e por consequência, os ombros (DRAKE; VOGL; MITCHELL, 2015).

3.2.1.2 *Latíssimo do dorso*

Latíssimo do dorso é um músculo de grande extensão, formato triangular e plano. Contém inserções na estrutura muscular regional devido ao revestimento que o trapézio realiza na porção superior. É responsável pela adução, extensão e rotação medial dos membros superiores. Atua também como músculo acessório da respiração (DRAKE; VOGL; MITCHELL, 2015).

3.2.1.3 *Levantador da escápula*

O levantador da escápula possui como sua principal ação, conforme sugere seu nome, a elevação da escápula. Se origina nos processos transversos das vértebras CI a CIV e se insere na parte superior da porção medial da escápula.


3.2.1.4 *Romboides menor e maior*

Os romboides menor e maior são músculos anexos que se encontram sob o trapézio e possuem a finalidade de retrainr ou puxar a escápula na direção da coluna vertebral. Com auxílio das demais musculaturas regionais, podem rotacionar a parte inferior da escápula. O romboide menor possui formato cilíndrico e situa-se acima do romboide maior (DRAKE; VOGL; MITCHELL, 2015).

3.2.2 Grupo médio

Após o grupo superficial, considerando-se os próximos músculos na direção da orientação anterior do corpo, existem duas camadas de músculos que são caracterizados como grupo médio. Essas duas camadas localizam-se nos hemisférios superior e inferior do dorso, possuindo um formato delgado (DRAKE; VOGL; MITCHELL, 2015). Os músculos pertencentes a esse grupo podem ser visualizados na Figura 17.

Figura 17 – Camada média dos músculos dorsais.



Fonte: Drake, Vogl e Mitchell (2015).

3.2.2.1 *Serrátil posterior superior e inferior*

São denominados serrátil posterior superior e inferior, grupos de músculos distintos que se fixam à coluna vertebral e demais estruturas relacionadas. Suas funcionalidades são principalmente as de movimentação. São auxiliares ao ato respiratório, com o grupo superior sendo responsável pela elevação das primeiras costelas e o inferior pela depressão das últimas. Essas ações caracterizam os atos de inspiração e expiração, respectivamente (DRAKE; VOGL; MITCHELL, 2015).

3.2.3 Grupo profundo

Os músculos do grupo profundo sustentam e movimentam a coluna vertebral, bem como parte dos movimentos da cabeça e as costelas em relação à coluna vertebral. Estendem-se da pelve ao crânio (DRAKE; VOGL; MITCHELL, 2015).

3.2.3.1 *Aponeurose toracolombar*

A aponeurose toracolombar é uma camada conjuntiva que reveste os músculos profundos, e é diretamente responsável por fornecer integridade e organização. Encontra-se em todas as camadas musculares do torso, sendo fixada nas vértebras torácicas pelo prolongamento posterior, chamado processo espinhoso e lateralmente, às costelas. Na região lombar, se divide em três camadas de maneira a revestir o eretor da espinha e o músculo quadrado do lombo e fixar-se aos processos transversos lombares (DRAKE; VOGL; MITCHELL, 2015).

3.2.3.2 *Músculos eretores da espinha*


A aglomeração dos músculos eretores da espinha inicia-se a partir de um tendão largo e espesso fixado ao sacro, processos espinhosos das vértebras lombares e torácicas baixas e da crista ilíaca. A movimentação de toda a estrutura vertebral provém em grande parte desses músculos, proporcionando a capacidade extensão e fortalecimento da região dorsal e cabeça. Os músculos regionais podem ser separados em 3 segmentos (DRAKE; VOGL; MITCHELL, 2015):

- Lateral: formada pelo músculo ilicostal, que se associa a elementos costais possuindo múltiplas inserções nas costas e processos transversos;

- Intermediária: formada pelo maior dos músculos desse conjunto, nomeado longuíssimo, que se origina no tendão comum acima do lombar, percorrendo todo o dorso e por fim fixando-se ao crânio;
- Medial: contém apenas o músculo espinal, sendo assim, a menor dos conjuntos regionais. É mais presente na região torácica e inexistente na região cervical. Esse grupo se associa ao semi-espinal quando próximo do crânio.

Os músculos apresentados encontram-se ilustrados na Figura 18.

Figura 18 – Músculos eretores da espinha do grupo profundo.



Fonte: Drake, Vogl e Mitchell (2015).

3.2.3.3 *Músculos espinotransversais*

Os espinotransversais são separados em dois músculos: o esplênio da cabeça e esplênio do pescoço. Possuem um formato longo e estreito e originam-se na parte baixa da cabeça inserindo-se na porção alta do dorso. Em conjunto, são responsáveis por prover o movimento para trás da cabeça, bem como individualmente rotacionam a cabeça para o lado do músculo que se contrai (DRAKE; VOGL; MITCHELL, 2015).

3.2.3.4 *Músculos transverso-espinais*

Os músculos transverso-espinais são imediatamente profundos aos músculos eretores da espinha. A ação desse grupo muscular é rotacionar o tronco e estender a coluna vertebral. Podem ser divididos em 3 subgrupos (DRAKE; VOGL; MITCHELL, 2015):

- Músculos semi-espinais: são fixados ao crânio com origem torácica, percorrendo de 4 a 6 vértebras. Apresenta-se de forma mais superficial que os demais;
- Multífido: esse grupo de músculos encontra-se por toda a extensão da coluna vertebral. Originam-se lateralmente e realizam uma inserção nos processos espinhosos, fixando-se em 2 a 4 vértebras;
- Músculos rotadores: são os mais profundamente inseridos desse grupo. Assim como o multífido, também encontram-se em toda extensão da coluna vertebral, com maior ocorrência na região torácica.


3.2.3.5 *Músculos segmentares*

Os músculos segmentares compõem um grupo formado pelos subgrupos de levantadores das costelas, os interespinais e intertransversários. Os levantadores das costelas são responsáveis pela movimentação das mesmas, elevando-as com sua contração. O segundo subgrupo tem a função auxiliar de permitir que outros grandes grupos se movimentem adequadamente, realizando para isso, uma estabilização das vértebras adjacentes (DRAKE; VOGL; MITCHELL, 2015).

3.2.3.6 *Músculos suboccipitais*

Músculos suboccipitais é o conjunto que movimenta a cabeça e conecta as vértebras CI e CII à parte baixa do crânio. Nesse grupo são incluídos: reto posterior maior da cabeça, reto posterior menor da cabeça, oblíquo inferior da cabeça e oblíquo superior da cabeça. A movimentação da cabeça como extensão ou rotação da face é realizada por esse conjunto muscular (DRAKE; VOGL; MITCHELL, 2015). Os músculos segmentares, transverso-espinais e suboccipitais podem ser visualizados na Figura 19.

Figura 19 – Músculos transverso-espinais e segmentares do grupo profundo.



Fonte: Drake, Vogl e Mitchell (2015).

3.3 FUNCIONALIDADES


A estrutura dorsal fornece três importantes funcionalidades para o corpo: sustentação, proteção e movimentação (DRAKE; VOGL; MITCHELL, 2015).

3.3.1 Sustentação

Nos adultos, o dorso possui curvaturas côncavas na região sacral e torácica, conhecidas como curvaturas primárias. Existem também curvaturas secundárias côncavas nas regiões cervical e lombar (DRAKE; VOGL; MITCHELL, 2015).

Esse formato anatômico cria uma linha gravitacional que admite uma posição bípede ereta de modo a se consumir o mínimo de energia muscular. As curvaturas podem ser visualizadas na Figura 20.

Figura 20 – Extensão da coluna vertebral e suas curvaturas.



Fonte: Drake, Vogl e Mitchell (2015).

A região dorsal, no que se refere à sustentação, também é responsável pela transmissão de força através da pelve para as extremidades inferiores, posicionamento da cabeça e movimentação dos membros superiores.


3.3.2 Movimentação

Os músculos intrínsecos e extrínsecos são responsáveis pela realização dos movimentos regionais e auxílio nos membros adjacentes. A musculatura extrínseca possibilita os movimentos dos membros superiores e das costelas e a intrínseca é responsável por manter a postura e permite a flexão, extensão, flexão lateral e rotação da região (DRAKE; VOGL; MITCHELL, 2015).

3.3.3 Proteção

A coluna vertebral e as partes brandas do sistema nervoso central presentes no dorso fornecem proteção às regiões do sistema nervoso central, constituída do encéfalo e da medula espinhal e periférica, composta dos nervos cranianos e espinais. Essa estrutura pode ser visualizada na Figura 21.

Figura 21 – Medula espinhal e suas adjacências.



Fonte: Drake, Vogl e Mitchell (2015).


3.4 ANATOMIA DE SUPERFÍCIE DA REGIÃO DORSAL

Na região dorsal humana, observa-se superficialmente marcos anatômicos que representam parcialmente estruturas musculares ou ósseas que encontram-se diretamente profundas à pele.

Os músculos eretores da espinha formam dois sustentáculos no formato de colunas que são separados medialmente pelo sulco mediano posterior. Esse sulco é visualmente identificável no plano frontal, com a pessoa ereta. Outros músculos como o trapézio, latíssimo do dorso e romboides também são visíveis. A maior profundidade ocorre na região torácica baixa e lombar alta, com a curvatura se acentuando exteriormente na região cervical (MOORE; DALLEY; AGUR, 2013).

Na Figura 22 são apresentadas a superfície do dorso e suas respectivas marcas anatômicas que podem ser visualizadas externamente.


Figura 22 – Anatomia de superfície do dorso.



Fonte: Schünke et al. (2010).

Na Figura 23 pode-se observar a coluna central dentre os músculos eretores da espinha, com destaque à coluna vertebral e a posição aproximada de algumas de suas vértebras, sendo também consideradas onde ocorrem as convexidades e concavidades regionais.

Figura 23 – Região dorsal externa com destaque à coluna vertebral.



Fonte: Lumley (2008).

Conforme Figura 23, os seguintes itens são representados:

1. Primeira vértebra torácica;
2. Vigésima vértebra torácica;
3. Quarta vértebra Lombar;

4. Margem lateral dos músculos eretores da espinha.

No capítulo a seguir, são apresentados estudos que utilizam os conceitos fundamentados e como os mesmos tem sido utilizados para obtenção de dados do corpo humano.


4 REVISÃO DA LITERATURA

No imageamento médico, abordagens como a utilização do valor de entropia têm sido utilizadas para segmentação de imagens. Kim, Choi e Nam (2016) desenvolveram um algoritmo que define um nível de importância para cada pixel, baseado no valor de entropia. Esse valor então é utilizado na fase de limiarização visando separar corretamente os itens desejados do plano de fundo. Sendo esse processo chamado de EBM (Entropy Based Masking).

O algoritmo desenvolvido, chamando Low-Pixel Resolution Entropy-Based Masking (LPREM) aplica uma redução no tamanho da imagem para minimizar o ruído aleatório e diminuir o tempo de processamento computacional.

Na Figura 24 é possível visualizar uma saída do algoritmo. Sendo a Figura 24 A), 24 B), 24 C) e 24 D) imagens para avaliação, 24 E) e 24 F) são resultados produzidos pelo algoritmo EBM e por fim 24 G) e H) sendo saídas do LPREM.

Figura 24 – Saída visual dos algoritmos EBM e LPREM.




Fonte: Kim, Choi e Nam (2016).

A solução apresentada se mostrou com melhor desempenho em relação a algoritmos como Otsu (1979) ou ActiveContours Chan e Vese (2001) e possui grau aceitável na saída visual qualitativa em imagens com objetos finos e estreitos.

No âmbito da avaliação de superfície da região dorsal, estudos têm sido realizados com o intuito de correlacionar a superfície externa e o imageamento convencional realizado por raios-x. Bergeron et al. (2005) realizaram um estudo que buscou correlacionar a superfície dorsal mapeada em 3D com sua geometria interna. Dados foram comparados utilizando uma aquisição em que duas radiografias posteroanteriores foram capturadas simultaneamente com pontos anatômicos adquiridos com um sistema laser. Obteve-se um erro de 6,13 mm e 4,38 mm para as visões laterais e frontais da coluna vertebral, respectivamente. Os autores julgaram que os exames radiográficos tendem a ser substituídos por avaliações que utilizem essa abordagem.

Poredoš et al. (2015) avaliaram a determinação da coluna vertebral utilizando o princípio da triangularização a laser. Na metodologia utilizada, um emissor laser projeta luz sobre a superfície a ser avaliada para que uma câmera sensível a essa iluminação adquira a informação necessária, mapeando a estrutura tridimensionalmente. O esquema utilizado por Poredoš et al. (2015) pode ser visto na Figura 25.

Figura 25 – Esquema de medição utilizando triangularização a laser.




Fonte: Poredoš et al. (2015).

No estudo de Poredoš et al. (2015) foram avaliadas 24 pessoas com o objetivo de comparar a curva gerada automaticamente pelo equipamento, com uma determinada manualmente, por meio do apalpamento da região. A curva automática foi definida utilizando o mapeamento da superfície realizada pelo equipamento, que foi determinada

baseando-se na variação de profundidade da região.

Na Figura 26 (a), pode-se visualizar áreas escuras que apresentam uma curvatura negativa e áreas claras, que são positivas. Na Figura 26 (b) são mostradas linhas candidatas à detecção da coluna, que é extraída com um clique do *mouse*.

Figura 26 – Imagens intermediárias da segmentação utilizando laser.



Fonte: Poredoš et al. (2015).

A comparação entre a curva manual e automática foi realizada com o cálculo do RMSD (*Root Mean Square Deviaton*) entre as curvas manual e a automática. Calculou-se que o RMSD típico é de 5 mm no plano frontal e 1 mm no sagital. Os autores concluíram que o método tem potencial para substituir as avaliações com raios-x permitindo uma determinação mais segura da coluna vertebral.


Korez et al. (2015) desenvolveram um conjunto de métodos, especializados na detecção e segmentação da coluna dorsal e suas vértebras. Essa detecção é feita de maneira automática e utiliza-se de imagens de tomografia em 3D. O procedimento executado em uma imagem de raios-x utilizando o *framework* desenvolvido, possui como primeira etapa a procura da coluna como um todo e em seguida, a busca pelas vértebras.

Para reconhecer as regiões, são utilizados conceitos da Teoria da Interpolação (SAKHNOVICH, 2012), em que conjuntos de dados discretos não conhecidos, mas desejados, podem ser construídos a partir de outros que foram identificados previamente.

A segmentação das vértebras é efetivada por intermédio de um conceito chamado *Model-Based Segmentation* ou Segmentação Baseado em Modelo. Quando utilizado, um

modelo com formato semelhante ao requerido é inserido na imagem, próximo à área a ser segmentada e é deformado e adaptado para a região desejada, utilizando suas bordas. A saída segmentada desse procedimento pode ser visto na Figura 27.


Figura 27 – Segmentação completa utilizando o *framework*.



Fonte: Korez et al. (2015).

Também têm sido realizadas pesquisas utilizando métodos de projeção de uma grade de pontos sobre a superfície a ser analisada. Mínguez et al. (2007) realizaram a avaliação topográfica da região dorsal para verificar deformações regionais. Pode ser visto na Figura 28, uma imagem de um mapa topográfico criado no estudo.

Figura 28 – Avaliação topográfica da região dorsal.



Fonte: Mínguez et al. (2007).

No total, foram avaliadas 86 pessoas, sendo 56 não patológicas e 30 com escoliose idiopática. Obtendo-se um valor de predição positiva de 82% Mínguez et al. (2007) concluíram que existe uma equivalência entre os valores topográficos e valores clínicos, como o ângulo de rotação vertebral.

Seoud et al. (2010) desenvolveram um sistema para análise de superfície do tronco que prediz o tipo de curva escoliótica. As pessoas avaliadas tiveram o tronco mapeados e reconstruídos em 3D. O sistema de aquisição é composto por 4 digitalizadores óticos que projetam luzes estruturadas, formando 4 imagens distintas. Essas imagens são então combinadas, e por triangularização, formam um mapa de profundidade da região. O sistema desenvolvido por Seoud et al. (2010) alcançou uma taxa de acerto de 72,2%, o que foi julgado como promissor e adequado.

A segmentação e avaliação da coluna vertebral também tem sido realizada com procedimentos que não utilizam processamento de imagens e visão computacional. Dispositivos como o Spinal Mouse (2017), que é apresentado na Figura 29 são também comumente utilizados.

Figura 29 – Avaliação de um paciente com o dispositivo Spinal Mouse®.



Fonte: Livanelioglu et al. (2016).

Para o uso do Spinal Mouse®, a coluna vertebral precisa ser demarcada externamente com antecedência para que o avaliador percorra toda sua extensão utilizando o dispositivo. Essa ação faz com que a coluna vertebral seja mapeada. Livanelioglu et al. (2016) verificaram a confiabilidade e a validade das avaliações realizadas pelo Spinal Mouse®, concluindo que o mesmo é adequado tanto para pesquisa quanto para acompanhamento de pacientes. Tornando a avaliação rápida, não-invasiva e sem efeitos colaterais.

Outros dispositivos que possuem funcionamento semelhante e tem sido estudados são:

Flexicurve (TEIXEIRA; CARVALHO, 2007), Epionics SPINE (CONSMÜLLER et al., 2012) e Spinal Posture Monitoring Device (Body-Guard) (O’SULLIVAN; CLIFFORD; HUGHES, 2010).

Nota-se que a avaliação da região dorsal tem se mantido em evidência na pesquisa científica. As abordagens com identificações sendo realizadas de modos diferentes, apresentam resultados favoráveis devido à estrutura musculoesquelética. Esses trabalhos fundamentam o algoritmo para segmentação da coluna vertebral desenvolvido neste estudo, que é apresentado no próximo capítulo.


5 DISLo (DORSAL IMAGE SPINE LOCATOR)

Para realizar a detecção da estrutura da coluna vertebral nas imagens, foi desenvolvido um algoritmo chamado DISLo (*Dorsal Image Spine Locator*) que realiza essa tarefa por meio de uma sequência de passos de processamento. A codificação foi realizada utilizando a biblioteca de visão computacional OpenCV 3.2 na versão para a linguagem de programação C++. A programação foi realizada no ambiente de desenvolvimento Eclipse Helios no sistema operacional Linux Mint 18.2.

5.1 ETAPAS DO ALGORITMO DISLo

O algoritmo DISLo tem como objetivo receber uma imagem da região dorsal e processá-la em etapas sequenciais, sem intervenção manual. O procedimento é executado visando obter ao final, uma saída que contenha uma representação da porção visualmente identificável da coluna vertebral presente na imagem inicial. As etapas sequenciais, iniciando-se com a entrada da imagem, até a produção da saída, podem ser separadas conforme o esquemático apresentado na Figura 30.

Figura 30 – Etapas de execução do algoritmo DISLo.



Fonte: Autoria própria.

5.1.1 Entrada

O algoritmo foi desenvolvido para executar adaptações nas imagens de entrada, tornando possível a avaliação de imagens independente de sua dimensão. A entrada deve conter uma imagem que seja somente o recorte da região dorsal de uma pessoa.

A seleção deve ser realizada considerando-se a extensão da coluna vertebral.

Verticalmente, deve-se iniciar na região lombar baixa, até a cervical baixa, próximo a linha dos ombros. Horizontalmente, deve conter a musculatura paravertebral visível.

Um exemplo de uma imagem pode ser vista na Figura 31 A) e na Figura 31 B) a imagem adequadamente recortada para entrada no algoritmo.

Figura 31 – A) Imagem inicial, B) entrada ideal para o algoritmo.




Fonte: Autoria própria.

5.1.2 Pré-processamento

A fase de pré-processamento é responsável pelo preparo da imagem para as etapas posteriores. É iniciado com a conversão da imagem original para 8 bits (256 tons de cinza) em um único canal.

Visando melhorar o contraste dos pixels, é realizada uma equalização do histograma da imagem (GONZALES; WOODS, 2011). Uma imagem de exemplo após a aplicação da equalização de histograma pode ser visualizada na Figura 32.

Figura 32 – Recorte da região dorsal em tom de cinza com histograma equalizado.



Fonte: Autoria própria.

5.1.2.1 Cálculo da entropia

O cálculo da entropia é realizado após a execução do pré-processamento, visto que nessa etapa a imagem ainda encontra-se com sua informação original. Por conta dessas características, o fim dessa fase é apropriado para o cálculo dessa métrica. Como exemplo, a Figura 32 possui um valor de entropia de 6,43.

A equação definida por Shannon (1948) foi codificada na presente etapa do DISLo. O cálculo é dividido em duas etapas. Na primeira, uma função para obter a ocorrência de cada nível de cinza é executado. Essa função retorna um vetor de 255 posições em que cada posição contém o respectivo número de ocorrências do nível de cinza. Conceitualmente, esse vetor é o histograma da imagem.

O algoritmo pode ser visto na Figura 33.

Figura 33 – Algoritmo responsável pelo cálculo da ocorrência de cada nível de cinza.

```

1: Função CALCULAHISTOGRAMA(Imagem I)
2:   declare totalLinhas  $\leftarrow$  I.quantidadeDeLinhas()
3:   declare totalColunas  $\leftarrow$  I.quantidadeColunas()
4:   declare Ocorrência[I.quantidadeDeNíveisDeCinza()]
5:   declare i, j
6:   Para i  $\leftarrow$  0 até totalLinhas faça
7:     Para j  $\leftarrow$  0 até totalColunas faça
8:       | Ocorrência[I[i,j]]++
9:     Fim Para
10:  Fim Para
11:  Retorne Ocorrência
12: Fim Função

```

Fonte: Autoria própria.

Após a obtenção do vetor com as ocorrências, a função de cálculo da entropia é executada, utilizando-se desses valores como parâmetros de entrada. O algoritmo pode ser visualizado na Figura 34.

Figura 34 – Algoritmo para cálculo de entropia.

```

1: Função CALCULAENTROPIA(Imagem I, Histograma hist)
2:   declare totalLinhas  $\leftarrow$  I.quantidadeDeLinhas()
3:   declare totalColunas  $\leftarrow$  I.quantidadeColunas()
4:   declare totalSímbolos  $\leftarrow$  totalLinhas * TotalColunas
5:   declare níveisDeCinza  $\leftarrow$  I.quantidadeDeNíveisDeCinza()
6:   declare ocorrência  $\leftarrow$  0
7:   declare entropia  $\leftarrow$  0, temp  $\leftarrow$  0, i, j
8:   Para i  $\leftarrow$  0 até níveisDeCinza faça
9:     ocorrência  $\leftarrow$  hist[i]
10:    Se ocorrência > 0 então
11:      temp  $\leftarrow$  (ocorrência/totalSímbolos) * log(totalSímbolos/ocorrência)
12:      entropia  $\leftarrow$  entropia + temp
13:    Fim Se
14:  Fim Para
15:  Retorne entropia
16: Fim Função

```

Fonte: Autoria própria.

5.1.3 Filtragem e separação

Nesta etapa removem-se componentes indesejados da imagem por meio da filtragem no domínio do espaço. Ao final do presente passo, tem-se uma imagem intermediária com informações sobre a localização da coluna vertebral.

5.1.3.1 *Filtro bilateral*

O filtro bilateral aplicado para suavização da imagem, é análogo ao filtro Gaussiano, com o diferencial de preservar as bordas da imagem. Com sua aplicação, cada pixel é substituído por uma média ponderada dos pixels de uma determinada janela de tamanho $n \times n$ com o adicional de um segundo parâmetro que representa a diferença de intensidade do pixel central. Isso faz com que a matriz de pesos contenha valores maiores para pixels mais semelhantes (BRADSKI; KAEHLER, 2008). A equação do filtro bilateral, conforme definido por Tomasi e Manduchi (1998), pode ser visto na Equação 7.

$$Y(x) = \frac{1}{W_p} \sum_{x_i \in \Omega} I(x_i) f_r(\|I(x_i) - I(x)\|) g_s(\|x_i - x\|) \quad (7)$$

Em que:

$$W_p = \sum_{x_i \in \Omega} f_r(\|I(x_i) - I(x)\|) g_s(\|x_i - x\|) \quad (8)$$

Os termos das Equações 7 e 8, são, respectivamente:

- I = Imagem original;
- Y = Imagem filtrada;
- f_r = Kernel para processamento das diferenças em intensidade;
- Ω = A janela com x ao centro;
- g_s = Kernel para processamento das diferenças espaciais;
- x = Coordenadas do pixel a ser filtrado.

É apresentado na Figura 35, a Figura 32 com a filtragem bilateral aplicada.

Figura 35 – Imagem filtrada bilateralmente.



Fonte: Autoria própria.

5.1.3.2 Detecção de bordas

Para a isolamento da região de interesse é necessário separar os contornos superficiais visíveis. Para esta tarefa utilizou um operador Prewitt (PREWITT, 1970) em sua forma estendida. Devido à orientação da coluna vertebral, foi utilizado somente a imagem de gradiente Gx , conforme Equação 9.

$$Gx = \begin{bmatrix} -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \end{bmatrix} \quad (9)$$

Foi utilizado um filtro estendido para que o novo pixel calculado leve em consideração uma região maior, diminuindo assim a ocorrência de ruídos locais. A imagem G_{mag} gerada após a aplicação do operador Prewitt pode ser visualizada na Figura 36.

Figura 36 – Imagem após a aplicação do filtro Prewitt estendido.



Fonte: Autoria própria.

5.1.3.3 Limiarização

No estado atual, a imagem contém a intensidade dos gradientes encontrados, portanto, contendo pixels com intensidades ainda variando entre 0 e 255. A limiarização é realizada considerando o valor da metade do espectro, conforme Equação 10.

$$G(x) = \begin{cases} 255, \text{ se } f(x, y) \geq 127 \\ 0, \text{ se } f(x, y) < 127 \end{cases} \quad (10)$$

A estrutura gerada após essa etapa é chamada de Composição Parcial, e pode ser vista na Figura 37.

Figura 37 – Composição parcial.



Fonte: Autoria própria.

5.1.3.4 Seleção de contornos

Comumente, após a identificação das bordas da imagem, mais de uma região é identificada, muitas vezes não possuindo qualquer conexão com as demais. O DISLo identifica e distingue cada uma dessas frações encontradas isoladamente, separando-as de acordo com seu contorno. Essa ação é realizada por meio da função da biblioteca OpenCV chamada *cv::findContours()*, que implementa a solução de Suzuki et al. (1985). Os contornos são definidos como sendo linhas contendo todos os pontos contínuos de uma borda e possuindo a mesma intensidade de cor (OPENCV, 2017). Um exemplo de identificação de contornos pode ser visto na Figura 38, em que são apresentadas regiões separadas em cores para melhor visualização.

Figura 38 – Exemplo de seleção de contornos.



Fonte: Autoria própria.

5.1.4 Parametrização

Nesta etapa, são adquiridas informações sobre as regiões até então identificadas. Essas informações têm o objetivo de fornecer características para as etapas posteriores do processamento morfológico.

5.1.4.1 Pontos extremos

Pontos Extremos são as ocorrências mais à esquerda e mais à direita de pixels com intensidade de valor 255. O algoritmo utilizado para obter os vetores pode ser visto na Figura 39.

Figura 39 – Algoritmo para cálculo dos pontos extremos à esquerda e direita.

```

1: Procedimento CALCULAPONTOSEXTREMOS(Imagem I)
2:   declare totalLinhas  $\leftarrow$  I.quantidadeDeLinhas()
3:   declare totalColunas  $\leftarrow$  I.quantidadeColunas()
4:   declare i,j
5:   declare pExtremosEsquerda[totalLinhas], pExtremosDireita[totalLinhas]
6:   Para i  $\leftarrow$  0 até totalLinhas faça
7:     Para j  $\leftarrow$  0 até totalColunas faça
8:       Se  $I[i, j] = 255$  então
9:         pExtremoEsquerda[i]=j
10:        break
11:      Fim Se
12:    Fim Para
13:    Para j  $\leftarrow$  totalColunas até 0, passo -1 faça
14:      Se  $I[i, j] = 255$  então
15:        pExtremoDireita[i] $\leftarrow$ j
16:      break
17:    Fim Se
18:  Fim Para
19:  Fim Para
20: Fim Procedimento

```

Fonte: Autoria própria.

Os Pontos Extremos formam dois vetores independentes, um para o lado esquerdo e outro para o direito, em que cada item desses vetores é a posição no eixo x em que é encontrado o pixel de intensidade 255. Para cada linha, os valores mais a esquerda e mais a direita são atribuídos aos seus respectivos vetores. Essa verificação é realizada em toda a extensão do eixo x da matriz da imagem, portanto o tamanho total dos vetores será o mesmo que o tamanho vertical da imagem.

5.1.4.2 *Parâmetros adicionais*

São obtidas características dos Vetores de Pontos Extremos, como a média do vetor à esquerda $\bar{x}_e$ e à direita $\bar{x}_d$, as respectivas variâncias σ_e^2 e σ_d^2 , desvios padrões σ_e e σ_d e coeficientes de variação CV_e e CV_d . Essa etapa é reexecutada cada vez que ocorre uma alteração na Composição Parcial.

5.1.5 *Aprimoramento*

Etapa do processamento em que é realizado o melhoramento visual da forma até então identificada, extraíndo ruídos remanescentes e melhorando sua morfologia.

5.1.5.1 *Remoção de excessos*

A Composição Parcial pode conter bordas que foram segmentadas, mas que não correspondem à coluna vertebral. Esse comportamento ocorre devido às bordas terem um perfil em que há pouca variação de tonalidade. Essas bordas adicionais tendem a se projetar para as extremidades da imagem.

Utilizando-se dos valores encontrados com as médias dos Vetores de Pontos Extremos, os excessos são então separados da estrutura central. A separação ocorre escolhendo-se um Ponto de Corte PC alterando a intensidade de toda uma coluna de pixels de acordo com as Equações 11 e 12.

$$PC_{esquerdo} = \bar{x}_e - \sigma_e \quad (11)$$

$$PC_{direito} = \bar{x}_d - \sigma_d \quad (12)$$

Após a separação os contornos são recalculados, identificando e removendo os excessos que estarão separados da estrutura principal. Um exemplo dessa separação e identificação

de novos contornos pode ser visualizada na Figura 40 A) e o resultado após a retirada na Figura 40 B).

Figura 40 – A) Regiões em excesso selecionadas B) Regiões removidas.



Fonte: Autoria própria.

5.1.5.2 *Ligamento de regiões de acordo com o centro de massa*

A seleção dos contornos pode levar em determinados casos, a escolha de segmentos que estão desconexos entre si. Se esses segmentos corresponderem às regiões musculares, que foram indicadas anteriormente, o procedimento de Ligação de Região é executado.

A ligação é realizada utilizando uma linha de 1 pixel de diâmetro e considerando o centro de massa das duas formas geométricas irregulares encontradas. O centro de massa é calculado utilizando os conceitos de Momentos Invariantes (MI), utilizado no OpenCV com a função `cv::moments()`. Os MI são calculados de acordo com a Equação 13 (OPENCV, 2014).

$$M_{i,j} = \sum_{x,y} (\text{vetor}(x,y) \cdot x^j \cdot y^i) \quad (13)$$

Em que os centros de massa x_c e y_c são calculados pela Equação 14.

$$x_c = \frac{M_{10}}{M_{00}}, y_c = \frac{M_{01}}{M_{00}} \quad (14)$$

Um exemplo de Ligação de Região é apresentado na Figura 41.

Figura 41 – Ligamento de regiões.



Fonte: Autoria própria.

Nota-se que dois segmentos distintos, separados por pixels de intensidade 0, foram conectados por meio de uma linha que representa a menor distância entre os centros de massa.

5.1.5.3 *Preenchimento de região*

Devido a variação da direção e intensidade do gradiente das imagens, a detecção de bordas ocasionalmente gera uma saída que pode conter falhas de preenchimento. Isso ocorre devido a intensidade de alguns pixels da saída gerada pelo operador Prewitt corresponder a um valor abaixo do limiar. Um exemplo de uma imagem após a limiarização e com falhas pode ser visualizada na Figura 42.

Figura 42 – Imagem com falhas de preenchimento.



Fonte: Autoria própria.

O algoritmo de preenchimento de brancos utiliza os Vetores de Pontos Extremos à esquerda e direita para alterar o valor de pixels de 0 para 255. A operação é realizada horizontalmente, linha a linha e considerando como ponto inicial o Vetor de Pontos Extremos à Esquerda, e final, o Vetor de Pontos Extremos à Direita.

O algoritmo para realizar esse procedimento pode ser visualizado na Figura 43.

Figura 43 – Algoritmo para preenchimento de região.

```

1: Função PREENCHECOMBRANCOS(Imagem I, pExtremosEsquerda, pExtremos-
   Direita)
2:   declare percorre  $\leftarrow$  0
3:   declare totalLinhas  $\leftarrow$  I.quantidadeDeLinhas()
4:   declare totalColunas  $\leftarrow$  I.quantidadeColunas()
5:   declare i
6:   Para i  $\leftarrow$  0 até totalColunas faça
7:     percorre  $\leftarrow$  pExtremosEsquerda[i]
8:     Se percorre  $\neq$  0 então
9:       Enquanto percorre  $\leq$  pExtremosDireita[i] faça
10:        I[i,percorre]  $\leftarrow$  255;
11:        percorre++
12:      Fim Enquanto
13:    Fim Se
14:  Fim Para
15:  Retorne I
16: Fim Função

```

Fonte: Autoria própria.

O resultado dessa operação na Figura 42 é apresentado na Figura 44.

Figura 44 – Imagem com regiões preenchidas.



Fonte: Autoria própria.

5.1.5.4 *Afinamento*

Para a obtenção da imagem de saída, é aplicado um algoritmo de afinamento para reduzir o resultado do processamento a uma estrutura simplificada e mais próxima do formato da coluna vertebral. O algoritmo utilizado é chamado Zhang-Suen (ZHANG; SUEN, 1984).

Esse algoritmo é executado em duas etapas sequenciais baseadas nas direções e vizinhanças de um pixel. Inicialmente são removidos os pixels à esquerda e acima, e em seguida, direita e abaixo. O algoritmo é interrompido quando não há pixels para serem removidos. Na Figura 45 pode-se visualizar a saída do algoritmo.

Figura 45 – Imagens do fim do processo de afinamento.



Fonte: Autoria própria.

5.1.5.5 Remoção de ruídos

Como processamento final, o DISLo busca novamente a ocorrência de excessos que podem ser gerados pelo afinamento que não correspondem à estrutura normal de uma coluna vertebral.

Para isso, são recalculados os Vetores de Pontos Extremos que devem ser iguais, visto que, a saída do afinamento é uma linha vertical uniforme. Se ocorrer diferença, o pixel é marcado como 0 e o ponto extremo daquela linha é recalculado.

Pode-se visualizar um exemplo dessa operação na Figura 46, em que (a) é a imagem com ruído e (b) a mesma imagem, corrigida.


Figura 46 – Imagem ao fim do processo de afinamento.



Fonte: Autoria própria.

A linha resultante de todo o processamento é a representação externa da musculatura. Considerando que os únicos pixels contendo valores 255 na imagem pertencem a essa representação, os mesmos podem ser descritos por um vetor contendo a posição no eixo x a qual pertencem. Por essas características esse vetor de valores é chamado de RVE (Representação Visual Externa). Na Figura 47 são apresentadas 4 imagens de entrada e suas respectivas RVEs.

Figura 47 – Imagens de entrada e seus respectivas RVEs obtidas pelo algoritmo DISLo.



Fonte: Autoria própria.

Nota-se que mesmo em imagens contendo pouca informação visual, devido ao tónus muscular variável, o algoritmo DISLo apresenta uma saída contendo uma RVE que abrange uma quantidade considerável da imagem de saída. Também é possível notar que devido à musculatura paravertebral ser adjacente à coluna vertebral, a curvatura existente na RVE tende também a acompanhar o respectivo desvio.

Para avaliação do algoritmo DISLo e da RVE produzida na saída, foram realizadas aquisições de imagens da região dorsal de voluntários. Os resultados obtidos são apresentados no próximo capítulo.

6 AVALIAÇÃO DAS IMAGENS

Neste capítulo são descritas as metodologias utilizadas na aquisição de imagens para avaliação da detecção da coluna vertebral, bem como os testes e os resultados obtidos da aplicação do DISLo em todas essas imagens e sua validação com imagens radiográficas.

6.1 IMAGENS UTILIZADAS

Para avaliação do algoritmo DISLo, foram utilizadas imagens de 70 pessoas que se candidataram e forneceram voluntariamente suas imagens à pesquisa. Dos voluntários, 58 se identificaram como sendo do sexo feminino e 12 do masculino, a idade média dos voluntários foi de $38,5 \pm 20$ anos. Dentre esses, 9 forneceram radiografias recentes e completas da região dorsal.

Todos os participantes concordaram em fornecer suas imagens para uso nesta pesquisa por meio da assinatura em um Termo de Consentimento Livre e Esclarecido proveniente do projeto 27/2011 do Comitê de Ética em Pesquisa da UNESP.

As imagens foram obtidas na rede pública municipal, especificamente nas Unidades Básicas de Saúde dos municípios de Ilha Solteira, estado de São Paulo e em Cassilândia, estado de Mato Grosso do Sul. Todo procedimento foi realizado por um fisioterapeuta e em ambiente clínico adequado.

A obtenção das imagens objetivou a visibilidade integral da região dorsal, portanto, foram adquiridas fotos no plano posterior de todas as 70 pessoas.

6.1.1 Metodologia de aquisição

Para cada foto, foi solicitado que o voluntário se mantivesse completamente ereto, com os braços rentes ao corpo e sem qualquer vestimenta na parte superior. Foi utilizada no processo de aquisição das imagens uma câmera de 8 megapixels possuindo uma lente com abertura de 2.4 f e distância focal de 35 mm.

Durante o processo de aquisição a câmera foi fixada a uma distância de 1,5 m do calcanhar do voluntário e 1,5 m de altura. Com essa padronização, todas as imagens tiveram o mesmo formato, que é apresentado na Figura 48.

Figura 48 – Exemplo de uma imagem adquirida pelo método apresentado.



Fonte: Autoria própria.

6.2 METODOLOGIA DE AVALIAÇÃO

Conforme fundamentado anteriormente, a alteração do relevo muscular de superfície da região dorsal produz uma alteração na musculatura, visualmente ocasionando uma alteração na informação e no valor de intensidade dos pixels da imagem.

A entropia fornece um meio de quantificar individualmente a informação de uma imagem e vem sendo utilizada para análise como uma forma de se obter informações sobre características ou ainda gerar parâmetros para separação de regiões de interesse (ELARABY et al., 2014; KIM; CHOI; NAM, 2016).

Como forma de mensurar a informação existente em imagens da região dorsal, verificou-se a relação entre o $H(x)$ individual e a informação visual existente em cada imagem. Para isso, realizou-se uma avaliação em que cada imagem teve um valor subjetivo atribuído, que foi posteriormente associado a um valor de entropia. Caracterizou-se essa avaliação como Qualitativa.

6.3 AVALIAÇÃO QUALITATIVA

Três avaliadores, possuindo formação e conhecimentos necessários quanto à anatomia humana, denominados A_1 , A_2 e A_3 , realizaram uma avaliação considerando as informações visuais existentes nas imagens. Definiu-se um conjunto de regras para manter a avaliação homogênea:

- Não haverá contato com as imagens antes das avaliações;
- Não haverá comunicação entre os demais avaliadores durante ou antes das avaliações;
- Não é permitido acesso às avaliações realizadas pelos outros dois avaliadores;
- Não é permitido acesso aos julgamentos realizados anteriormente;
- Não será fornecido o valor de entropia $H(x)$ de nenhuma imagem;
- As avaliações serão realizadas sucessivamente, da primeira à última amostra, sem interrupções.

Para o procedimento, A_1 , A_2 e A_3 avaliaram as 70 imagens que foram disponibilizadas aleatoriamente. Durante o julgamento, as seguintes regras foram utilizadas:

- Cada imagem deverá ser avaliada entre três valores numéricos inteiros, de 1 a 3:
 1. Visibilidade baixa;
 2. Visibilidade média;
 3. Visibilidade alta.
- Este valor deverá ser atribuído a cada imagem, de acordo com o julgamento da visibilidade da musculatura paravertebral;
- Pode-se discordar da imagem de exemplo, desde que se mantenha uma avaliação numérica utilizando os 3 níveis de visibilidade;
- Cada imagem será avaliada duas vezes;
- A imagem de exemplo estará disponível sempre que necessário;
- O intervalo entre a sequência de avaliações para cada avaliador será de no mínimo 24 horas.

Para orientação dos avaliadores, uma imagem contendo um exemplo para cada um dos possíveis valores foi fornecida, essa imagem pode ser vista na Figura 49.


Figura 49 – Imagem contendo exemplos de classificação.



Fonte: Autoria própria.


Após os julgamentos, o avaliador A_1 produziu os valores presentes na Figura 50.

Figura 50 – Valores qualitativos do avaliador A_1 .




Fonte: Autoria própria.

O avaliador A_2 gerou os valores apresentados na Figura 51.

Figura 51 – Valores qualitativos do avaliador A_2 .

Fonte: Autoria própria.

O avaliador A_3 julgou o conjunto de imagens com os valores apresentados na Figura 52.


Figura 52 – Valores qualitativos do avaliador A_3 .

Fonte: Autoria própria.

Conforme pode ser visualizado na comparação entre os gráficos da Figura 50, 51 e 52, a subjetividade e a liberdade de escolha proveniente desse tipo de avaliação ocasiona uma variação nas atribuições inter e intra avaliadores. Por conta desse comportamento, um valor individual que considere todo o espectro dos julgamentos a cada imagem se mostra necessário. Esse valor foi calculado arredondando a média dentre todos os 6 valores de

cada imagem. Com o cálculo desses valores para todas as imagens, o gráfico da Figura 53 é gerado.

Figura 53 – Grupos de avaliação após a média das avaliações de A_1 , A_2 e A_3 .




Fonte: Autoria própria.

Nota-se na Figura 53 que considerando as classificações realizadas por A_1 , A_2 e A_3 , 37 indivíduos possuem uma musculatura paravertebral de superfície que pode corresponder a uma visibilidade maior da coluna vertebral. Número este que corresponde a 52,85% do total de amostras, abrangendo a maioria das pessoas avaliadas. Por fim, 19 (27,15%) voluntários se encontram no grupo de visualização média e 14 (20%) no grupo de baixa visualização.

6.4 ASSOCIAÇÃO ENTRE AVALIAÇÃO QUALITATIVA E ENTROPIA

O algoritmo DISLo realiza o cálculo de $H(x)$ na última etapa em que a informação original da imagem ainda encontra-se disponível. Logo, as imagens de entrada encontram-se com 256 níveis de cinza, produzindo um $H(x)_{Max} = \log_2(256) = 8$.

Utilizando os valores qualitativos atribuídos a cada imagem, torna-se possível criar uma associação com os respectivos valores de entropia. Realizando essa associação, considerando o valor individual $H(x)$ calculado pelo algoritmo DISLo, gera-se o gráfico apresentado na Figura 54.

Figura 54 – Associação entre entropia e avaliação qualitativa.**Fonte:** Autoria própria.

Em relação aos intervalos entrópicos, o mínimo obtido no grupo de baixa visibilidade é de 3,91 e o maior é 6,22, já no grupo de alta visibilidade, o intervalo é entre 4,75 a 6,76. O grupo intermediário possui uma amplitude de valores maior, variando entre 4,21 e 6,74.

Nota-se que visualmente existe uma tendência dos valores se agruparem mais próximos de 0 no grupo de baixa visibilidade e mais próximo de $H(x)_{Max}$ no grupo de alta visibilidade. Essa tendência crescente pode ser verificada pelos valores apresentados na Tabela 1, em que a média é dada por $\bar{x}$, a variância por σ^2 , o desvio padrão por σ e o coeficiente de variação por CV .

Tabela 1 – Dados dos grupos quando associadas à $H(x)$.

Grupo	$\bar{x}$	σ^2	σ	CV
Visibilidade baixa	5,26	0,599	0,774	0,147
Visibilidade média	5,43	0,462	0,680	0,125
Visibilidade alta	6,12	0,257	0,507	0,083

Fonte: Autoria própria.

Conforme Tabela 1, o grupo qualitativo em que as imagens são classificadas como contendo uma baixa visibilidade, possui um valor de entropia médio menor que os demais, sendo 0,17 menor em relação ao grupo de visibilidade média e 0,86 em relação ao alto. Assim como o grupo de visibilidade média, se mantém como intermediário, possuindo uma

entropia média com a diferença de 0,69 em relação ao grupo de visibilidade alta. Nota-se que existe uma correlação entre a quantidade de informação existente nas imagens e a avaliação qualitativa.

O grupo de visibilidade baixa apresenta a maior dispersão dentre os grupos, característica dada pelo CV 0,022 maior que o grupo médio e 0,064 maior que o grupo de visibilidade alta. Os valores do grupo visibilidade alta possuem uma concentração mais homogênea dentre os demais.

Para a criação de grupos entrópicos que correspondem às avaliações qualitativas, é necessário definir os intervalos correspondentes. Foram considerados os valores médios entre cada um dos $\bar{x}$ e seu grupo subsequente da Tabela 1, sendo definidos conforme Tabela 2.

Tabela 2 – Valores de entropia e seus respectivos grupos qualitativos.

Grupo qualitativo	Intervalo entrópico
Visibilidade baixa	$<5,34$
Visibilidade media	$\geq 5,34$ e $<5,77$
Visibilidade alta	$\geq 5,77$

Fonte: Autoria própria.

Dispondo de um intervalo em que as imagens possam ser classificadas de acordo com sua quantidade de informação, torna-se possível separá-las e avaliá-las conforme seu grupo de visibilidade baseado em seu valor entrópico.

6.5 AVALIAÇÃO DA RVE


O algoritmo DISLo tem por objetivo realizar a extração da porção visível da coluna vertebral. Essa abordagem torna necessário avaliar cada imagem de saída considerando o quanto o algoritmo é capaz de extrair, visto que, a quantidade de informação visual é variável.

Como a estrutura da RVE é uma abstração de uma parte específica da imagem, é possível calcular sua proporção em relação ao tamanho total da imagem. Portanto, a proporção da RVE é considerada o quanto a coluna vertebral de determinada pessoa foi identificada.

Para essa avaliação, considerou-se a porcentagem de identificação em quatro grupos que representam a proporção identificada, sendo eles: de 0% a 25% , 26% a 50%, 51% a

75% e 76% a 100%. Quando esses grupos são correlacionados com os grupos entrópicos definidos na Tabela 2 obtém-se o gráfico da Figura 55.

Figura 55 – Proporção total em relação ao tamanho da imagem.



Fonte: Autoria própria.

Observa-se que o algoritmo DISLo obtém saídas com identificação maiores que 75% em todos os grupos, assim como mantém as identificações no intervalo de menos de 25% no mínimo. Considerando somente as quatro categorias, sem a classificação entrópica, pode visualizar na Tabela 3 a totalidade da amostra.

Tabela 3 – Proporção da identificação de acordo com os grupos.

Grupo	Total	Porcentagem
0% a 25%	3	4,3%
26% a 50%	10	14,3%
51% a 75%	17	24,3%
76% a 100%	40	57,1%

Fonte: Autoria própria.


Essas características evidenciam a robustez do algoritmo que se mostra capaz de extrair informação da maioria das imagens mesmo considerando as que possuem um valor de entropia baixo.

6.6 SEGMENTAÇÃO MANUAL E COMPARAÇÃO COM AS RVE'S

Para avaliação da segmentação que o algoritmo DISLo produz, os avaliadores A_1 , A_2 e A_3 realizaram uma segmentação manual em todas as 70 imagens. Esse procedimento foi realizado em um computador, utilizando o *mouse* como dispositivo de entrada.

As segmentações foram realizadas utilizando as imagens recortadas, e em coloração original. Para cada foto, uma linha de 1 pixel horizontal foi traçada na localização em que o avaliador considerou como a localização da coluna vertebral. Cada foto foi segmentada 3 vezes, totalizando ao final, 9 segmentações distintas para cada voluntário. Exemplificações de segmentações realizadas pelo método descrito podem ser vistas na Figura 56.

Figura 56 – Exemplos de imagens segmentadas manualmente.



(a) (b) (c)

Fonte: Autoria própria.

6.6.1 Extração e imagem média


Para uma representação em uma única imagem, extraíram-se as linhas de segmentação manual para cada foto, somando-as para obter uma única imagem média $\overline{M}$. A utilização dessa metodologia permite remover erros que possam ocorrer durante os julgamentos individuais de cada avaliador.

A saída $\overline{M}$ é uma imagem de 8 bits, de um único canal, em que existe a linha média de pixels no valor 255 e os demais contêm o valor 0.

O somatório de todas as 9 segmentações, após extraídas e inseridas em uma imagem,

pode ser visualizado na Figura 57(a), a imagem média $\bar{M}$ obtida pode ser vista na Figura 57(b), bem como a sobreposição da imagem média com a imagem que é apresentada na Figura 57(c).

Figura 57 – (A) Imagem intermediária contendo o somatório de todas as segmentações (B) Imagem $\bar{M}$ (C) Sobreposição de $\bar{M}$ e imagem original.



Fonte: Autoria própria.

A obtenção de todas as imagens $\bar{M}$ permite que sejam realizadas as comparações entre as saídas adquiridas pelo algoritmo DISLo e as segmentações manuais.

6.7 COMPARAÇÃO DOS MÉTODOS MANUAL E AUTOMÁTICO

Para comparação entre as linhas geradas automaticamente e as imagens $\bar{M}$, utilizou-se a Raiz do Erro Quadrático Médio (REQM), do inglês RMSE (*Root Mean Square Error*) também chamado RMSD (*Root Mean Square Deviation*), conforme Equação 15.

$$RMSD_{X-\bar{M}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{M}_i)^2} \quad (15)$$

Uma avaliação utilizando RMSD foi realizada por Poredoš et al. (2015) em um estudo semelhante, visando quantificar a diferença entre linhas geradas automaticamente e manualmente em uma avaliação da coluna vertebral.

Essa abordagem permite verificar a diferença entre os pixels X_i da imagem segmentada automaticamente e $\bar{M}_i$, sendo essa diferença caracterizada como Pontos Residuais. O

resultado da Equação 15 que é a raiz quadrada do desvio padrão desses resíduos, permite verificar o quanto um determinado conjunto de valores é divergente.

O cálculo do RMSD realizado pelo algoritmo DISLo é implementado em duas etapas. Na primeira, é realizada a obtenção da RVE da imagem de saída e a linha média da segmentação manual. Ambas são obtidas por meio do algoritmo apresentado na Figura 58.

Figura 58 – Algoritmo para extração da segmentação automática e manual.

```

1: Função VETORDEBRANCOS(Imagem I)
2:   declare totalLinhas  $\leftarrow$  I.quantidadeDeLinhas()
3:   declare totalColunas  $\leftarrow$  I.quantidadeColunas()
4:   declare vetorDeBranco[s][totalLinhas]
5:   declare i, j
6:   Para i  $\leftarrow$  0 até totalLinhas faça
7:     vetorDeBranco[s][i]  $\leftarrow$  0
8:     Para j  $\leftarrow$  0 até totalColunas faça
9:       Se I[i, j]  $\neq$  0 então
10:        |   vetorDeBranco[s][i]  $\leftarrow$  j
11:       Fim Se
12:     Fim Para
13:   Fim Para
14:   Retorne vetorDeBranco
15: Fim Função

```

Fonte: Autoria própria.

Após a obtenção do *vetorDeBranco* para X e $\bar{M}$ para todas as imagens e separando-as de acordo com os grupos entrópicos, um valor de RMSD médio ($\overline{RMSD}$) é obtido, conforme apresentado na Tabela 4.

Tabela 4 – Grupos entrópicos e suas características.

Grupo entrópico	$\overline{RMSD}$	σ^2	σ	CV
$<5,34$	9,28	0,18	0,42	0,04
$\geq 5,34$ e $\leq 5,77$	7,98	0,02	0,15	0,01
$>5,77$	6,93	0,29	0,08	0,01


Fonte: Autoria própria.

Avaliando todas as amostras, o $\overline{RMSD}$ é de 7,7 com $\sigma^2 = 7,04$, $\sigma = 2,65$ e $CV =$

0,34. Nota-se que o valor de entropia médio é inversamente proporcional ao valor de $\overline{RMSD}$. Mostrando que imagens com entropia alta, quando processadas pelo algoritmo DISLo, tendem a produzir uma saída mais semelhante ao realizado manualmente em relação as que contém baixa entropia.

Correlacionando os valores RMSD obtidos para todas as imagens e a proporção da linha da saída, tem-se o gráfico apresentado na Figura 59.

Figura 59 – Correlação entre a porcentagem identificada e o RMSD de cada imagem.



Fonte: Autoria própria.

Observa-se que existe uma tendência de diminuição do RMSD conforme a porcentagem de identificação aumenta. Portanto, imagens com maior identificação são consideradas mais semelhantes em relação à segmentação manual.

6.8 COMPARAÇÃO DAS RVE'S COM IMAGENS RADIOGRÁFICAS

Para mensurar a correlação entre a segmentação realizada pelo DISLo em relação à coluna vertebral interna e também validar a metodologia e saída do DISLo, utilizou-se 9 radiografias fornecidas por voluntários distintos.


6.8.1 Comparação com imagens radiográficas

Visando uma equivalência com a metodologia de obtenção de RVE do algoritmo DISLo, as radiografias utilizadas para comparação exibem a coluna vertebral da região

lombar baixa, até a cervical baixa. Todas as radiografias foram digitalizadas para que os procedimentos fossem realizados em um computador.

Realizou-se manualmente a marcação do centro de cada vértebra considerando o corpo vertebral como um todo. Após a identificação e marcação de cada ponto central, uma linha reta entre cada par de pontos foi traçada, gerando uma imagem semelhante ao RVE produzido pelo DISLo. Uma exemplificação da radiografia marcada e da RVE equivalente pode ser visto na Figura 60.

Figura 60 – (a) Radiografia com marcações em vermelho próximo ao centro de cada corpo vertebral, (b) RVE equivalente.



Fonte: Autoria própria.

6.8.2 Comparação com as respectivas RVE's

Assim como realizado na comparação das RVE's manuais e automáticas, utilizou-se o RMSD para mensurar a semelhança quantitativa com a RVE equivalente obtida das imagens radiográficas. O cálculo foi realizado utilizando os pixels da RVE equivalente da radiografia no lugar de $\overline{M}$ na Equação 15. Os valores obtidos para os 9 voluntários podem ser visualizados na Tabela 5.

Tabela 5 – Valores de RMSD obtidos utilizando a RVE equivalente da imagem radiográfica.


Voluntário	RMSD
1	6,44
2	3,46
3	12,9
4	9,6
5	9,43
6	6,28
7	3,25
8	3,29
9	5,09

Fonte: Autoria própria.

O RMSD médio $\overline{RMSD}_{rx}$ dos valores da Tabela 5 é de 6,73, sendo 0,97 pixels mais semelhante à RVE automática em relação à RVE manual.

A associação entre os valores RMSD e a entropia $H(x)$ das imagens dorsais pode ser visto na Figura 61.

Figura 61 – Associação entre os valores RMSD das radiografias avaliadas e da entropia de suas respectivas imagens dorsais.



Fonte: Autoria própria.

Percebe-se que a tendência do valor de entropia ser inversamente proporcional ao RMSD se mantém, conforme apresentado na Tabela 4.

Considerando as classes, conforme definidas na Tabela 2, os grupos entrópicos possuem um $\overline{RMSD}_{rx}$ conforme pode ser visto na Tabela 6.

Tabela 6 – Grupos entrópicos das imagens dorsais das radiografias e seus respectivos RMSD médios.

Grupo entrópico	$\overline{RMSD}_{rx}$
$<5,34$	11,25
$\geq 5,34$ e $\leq 5,77$	5,59
$>5,77$	4,53

Fonte: Autoria própria.

Os valores $\overline{RMSD}_{rx}$ da Tabela 6 quando associados aos valores $\overline{RMSD}$ da avaliação da RVE manual apresentados na Tabela 4, exibem uma diferença de aproximadamente ± 2 pixels para todos os grupos entrópicos. Sendo a diferença de $\overline{RMSD}_{rx} - \overline{RMSD}$ é de +1,97 para o grupo de baixa entropia, -2,39 para o grupo de entropia média e -2,4 para o grupo de alta entropia.

Considerando os resultados obtidos utilizando os valores de validação apresentados, adquiridos utilizando imagens e equipamentos amplamente adotados na área médica, as conclusões e trabalhos futuros deste estudo são discutidas no próximo capítulo.

7 CONCLUSÕES

Neste estudo avaliou-se a segmentação da coluna vertebral humana. A avaliação foi realizada por meio da extração da informação visual de imagens externas no plano frontal posterior de 70 voluntários.

As imagens foram separadas em grupos de acordo com a correlação entre a quantidade de informação, dada pela entropia da imagem, e seu valor subjetivo, definido pela avaliação média de julgamentos qualitativos realizados por 3 avaliadores. Verificou-se que o valor de entropia das imagens da região dorsal está associado à avaliação qualitativa relacionada à visibilidade da musculatura paravertebral, sendo maior em imagens com mais visibilidade e menor em imagens com menos visibilidade.

Para a segmentação da coluna vertebral, desenvolveu-se um algoritmo chamado DISLo que realiza o processamento de imagens da região dorsal. Após as etapas de processamento, o DISLo gera como saída uma imagem binarizada que contém uma linha de pixels de intensidade 255 representando a coluna vertebral presente na imagem.

A segmentação realizada de maneira automática pelo DISLo identificou uma proporção maior que 75% da coluna vertebral na maioria dos casos, em todos os grupos e mesmo em imagens contendo um baixo valor de entropia, ou seja, baixa visibilidade da musculatura.

A segmentação automática foi avaliada por meio do cálculo do RMSD entre a imagem de saída do algoritmo DISLo e outra segmentação realizada manualmente. A imagem de segmentação manual é a média de 9 segmentações realizadas por 3 avaliadores. Verificou-se que imagens com maior entropia geram saídas com RMSD menor, logo possuindo uma similaridade maior em relação à segmentação manual, obtendo um $\overline{RMSD}$ de $7,7 \pm 2,65$ pixels.

A avaliação realizada neste estudo mostra que a identificação da coluna vertebral utilizando unicamente imagens externas da região dorsal pode ser realizada, obtendo-se um resultado próximo do realizado manualmente.

Este resultado foi comparado a 9 radiografias que produziram um RMSD médio $\overline{RMSD}_{rx}$ com aproximadamente ± 2 pixels de diferença para todos os grupos entrópicos, em relação à $\overline{RMSD}$ da RVE manual.

Portanto, o uso de imagens dorsais externas é viável na obtenção de informações para a realização de exames da coluna vertebral. Proporcionando uma diminuição do custo e tempo na realização de avaliações de pacientes devido à utilização de somente uma câmera digital convencional para aquisição das imagens.

7.1 TRABALHOS FUTUROS

Devido a variação de qualidade das imagens da região dorsal provenientes do tônus muscular, a segmentação pode ser melhorada se utilizada implementações adaptativas em funções como as de filtragem ou obtenção de bordas. A adaptação de parâmetros como tamanho do kernel tende a produzir resultados diferentes que podem ser adicionados aos já existentes. fornecendo informações adicionais às etapas posteriores.

Tecnologias adicionais como Aprendizado de Máquina (*Machine Learning* - *ML*) têm se proposto a melhorar a análise e identificação de estruturas a nível de pixels. Isso é proveniente de seu enfoque em alto nível, que possibilita identificar diretamente características e descritores das imagens. Habilitando assim, atribuição de rótulos, identificação de regiões e reconhecimento de padrões (ALPAYDIN, 2016). A área de diagnósticos e processamento tem passado por uma mudança de paradigma devido ao Aprendizado de Máquina produzir resultados mais confiáveis do que as análises convencionais (RECHT; BRYAN, 2017; OBERMEYER; EMANUEL, 2016).

Espera-se que utilizando Aprendizado de Máquina, seja possível encontrar características ausentes nas imagens. Diversas áreas como: pescoço, pélvis, ombros e braços contém informações relevantes para estimar o posicionamento da coluna vertebral.

Para a avaliação de voluntários, pode-se considerar parâmetros de distância em centímetros. Essa abordagem pode ser alcançada por meio da utilização de um ponto de referência em todas as imagens obtidas, implementando no DISLo um método para obtenção e cálculo dessa referência. Com isso as avaliações podem ser realizadas também considerando a distância real entre determinados pontos.

REFERÊNCIAS

- ALPAYDIN, E. **Machine learning: the new AI**. Boston: MIT Press, 2016. 224 p.
- ASHER, M. A.; BURTON, D. C. Adolescent idiopathic scoliosis: natural history and long term treatment effects. **Scoliosis**, Londres, v. 1, n. 1, p. 2, 2006.
- BERGERON, C.; LABELLE, H.; RONSKY, J.; ZERNICKE, R. Robust prediction of three-dimensional spinal curve from back surface for non-invasive follow-up of scoliosis. In: MEDICAL IMAGING 2005: VISUALIZATION, IMAGE-GUIDED PROCEDURES, AND DISPLAY, 1., 2005, San Diego. **Anais...** San Diego: International Society for Optics and Photonics. 2005. p. 772–781.
- BRADSKI, G.; KAEHLER, A. **Learning OpenCV: computer vision with the OpenCV library**. Estados Unidos: O'Reilly Media, 2008. 575 p.
- CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, Estados Unidos, v. 10, n. 2, p. 266–277, 2001.
- CONSMÜLLER, T.; ROHLMANN, A.; WEINLAND, D.; DRUSCHEL, C.; DUDA, G. N.; TAYLOR, W. R. Comparative evaluation of a novel measurement tool to assess lumbar spine posture and range of motion. **European Spine Journal**, Alemanha, v. 21, n. 11, p. 2170–2180, 2012.
- DRAKE, L. R.; VOGL, A. W.; MITCHELL, W. M. **Gray's anatomy for students**. 3. ed. Canada: Elsevier, 2015. 1161 p.
- DUDA, R. O.; HART, P. E. **Pattern recognition and scene analysis**. Nova York: Wiley, 1973. 482 p.
- ELARABY, A.; EL-OWNY, H. B. M. A.; HESHMAT, M.; RADY, A. A. New algorithm for edge detection in medical images based on minimum cross entropy thresholding. **International Journal of Computer Science Issues - IJCSI**, Doolar Lane, v. 11, n. 2, p. 196, 2014.
- GARGANI, L.; PICANO, E. The risk of cumulative radiation exposure in chest imaging and the advantage of bedside ultrasound. **Critical ultrasound journal**, Milão, v. 7, n. 1, p. 4, 2015.
- GONZALES, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. São Paulo: Prentice Hall, 2011. 624 p.
- KIM, D.; CHOI, J.; NAM, J. Entropy-assisted image segmentation for nano-and micro-sized networks. **Journal of microscopy**, Estados Unidos, v. 262, n. 3, p. 274–294, 2016.

KOREZ, R.; IBRAGIMOV, B.; LIKAR, B.; PERNUŠ, F.; VRTOVEC, T. A framework for automated spine and vertebrae interpolation-based detection and model-based segmentation. **IEEE Transactions on Medical Imaging**, Estados Unidos, v. 34, n. 8, p. 1649–1662, 2015.

LIVANELIOGLU, A.; KAYA, F.; NABIYEV, V.; DEMIRKIRAN, G.; FIRAT, T. The validity and reliability of spinal mouse assessment of spinal curvatures in the frontal plane in pediatric adolescent idiopathic thoraco-lumbar curves. **European Spine Journal**, Berlim, v. 25, n. 2, p. 476–482, 2016.

LUMLEY, J. S. **Surface anatomy: the anatomical basis of clinical examination**. 4. ed. China: Elsevier Health Sciences, 2008. 136 p.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento digital de imagens**. Rio de Janeiro: Brasport, 1999. 307 p.

MÍNGUEZ, M. F.; BUENDÍA, M.; CIBRIÁN, R. M.; SALVADOR, R.; LAGUÍA, M.; MARTÍN, A.; GOMAR, F. Quantifier variables of the back surface deformity obtained with a noninvasive structured light method: evaluation of their usefulness in idiopathic scoliosis diagnosis. **European Spine Journal**, Berlim, v. 16, n. 1, p. 73–82, 2007.

MOORE, K. L.; DALLEY, A. F.; AGUR, A. M. **Clinically oriented anatomy**. 7. ed. Filadélfia: Lippincott Williams & Wilkins, 2013. 1168 p.

OBERMEYER, Z.; EMANUEL, E. J. Predicting the future—big data, machine learning, and clinical medicine. **The New England Journal of Medicine**, Boston, v. 375, n. 13, p. 1216, 2016.

OPENCV. **OpenCV**: structural analysis and shape descriptors. Estados Unidos: OpenCV. 2014. Disponível em: <<https://docs.opencv.org>>. Acesso em: 19 de mar. 2018.

OPENCV. **OpenCV website**. Estados Unidos: OpenCV. 2017. Disponível em: <<https://opencv.org/>>. Acesso em: 10 de nov. 2017.

O’SULLIVAN, K.; CLIFFORD, A.; HUGHES, L. The reliability of the coda motion analysis system for lumbar spine analysis: a pilot study. **Physiotherapy Practice and Research**, Lansdale, v. 31, n. 1, p. 16–22, 2010.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, Estados Unidos, v. 9, n. 1, p. 62–66, 1979.

O’CALLAGHAN, J.; WELLS, J.; RICHARDSON, S.; HOLMES, H.; YU, Y.; WALKER-SAMUEL, S.; SIOW, B.; LYTHGOE, M. F. Is your system calibrated? mri gradient system calibration for pre-clinical, high-resolution imaging. **PLoS One**, San Francisco, v. 9, n. 5, p. e96568, 2014.

PARKER, J. R. **Algorithms for image processing and computer vision**. 2. ed. Indianapolis: John Wiley & Sons, 2010. 504 p.

PETROU, M.; PETROU, C. **Image processing: the fundamentals**. 2. ed. Estados Unidos: John Wiley & Sons, 2010. 818 p.

- PICANO, E.; VAÑÓ, E.; REHANI, M. M.; CUOCOLO, A.; MONT, L.; BODI, V.; BAR, O.; MACCIA, C.; PIERARD, L.; SICARI, R. The appropriate and justified use of medical radiation in cardiovascular imaging: a position document of the esc associations of cardiovascular imaging, percutaneous cardiovascular interventions and electrophysiology. **European heart journal**, Oxford, v. 35, n. 10, p. 665–672, 2014.
- POREDOŠ, P.; ČELAN, D.; MOŽINA, J.; JEZERŠEK, M. Determination of the human spine curve based on laser triangulation. **BMC medical imaging**, Londres, v. 15, n. 1, p. 2, 2015.
- PREWITT, J. M. Object enhancement and extraction. **Picture processing and Psychopictorics**, Nova York, v. 10, n. 1, p. 15–19, 1970.
- RECHT, M.; BRYAN, R. N. Artificial intelligence: Threat or boon to radiologists? **Journal of the American College of Radiology**, Virgínia, v. 14, n. 11, p. 1476–1480, 2017.
- ROBERTS, L. G. **Machine perception of three-dimensional solids**. 82 f. 1963. Tese (Doutorado em Engenharia Elétrica) - Massachusetts Institute of Technology, Cambridge, 1963.
- RONCKERS, C. M.; DOODY, M. M.; LONSTEIN, J. E.; STOVALL, M.; LAND, C. E. Multiple diagnostic x-rays for spine deformities and risk of breast cancer. **Cancer Epidemiology and Prevention Biomarkers**, Philadelphia, v. 17, n. 3, p. 605–613, 2008.
- SAKHNOVICH, L. A. **Interpolation theory and its applications**. Canadá: Springer Science & Business Media, 2012. 220 p.
- SCHÜNKE, M.; SCHULTE, E.; SCHUMACHER, U.; ROSS, L. M.; LAMPERTI, E. D. **Thieme atlas of anatomy**. 2. ed. New York: Thieme Stuttgart, 2010. 624 p.
- SELBY, B. P.; SAKAS, G.; GROCH, W.-D.; STILLA, U. Patient positioning with x-ray detector self-calibration for image guided therapy. **Australasian physical & engineering sciences in medicine**, Nova York, v. 34, n. 3, p. 391, 2011.
- SEOUD, L.; ADANKON, M. M.; LABELLE, H.; DANSEREAU, J.; CHERIET, F. Prediction of scoliosis curve type based on the analysis of trunk surface topography. In: BIOMEDICAL IMAGING: FROM NANO TO MACRO, 7., 2010, Holanda. **Anais...** Holanda: IEEE. 2010. p. 408–411.
- SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, Nova York, v. 1, n. 27, p. 379–423, 1948.
- SMITH, J. S.; SHAFFREY, C. I.; BESS, S.; SHAMJI, M. F.; BRODKE, D.; LENKE, L. G.; FEHLINGS, M. G.; LAFAGE, V.; SCHWAB, F.; VACCARO, A. R. Recent and emerging advances in spinal deformity. **Neurosurgery**, Oxford, v. 80, n. 3S, p. S70–S85, 2017.
- SPINAL MOUSE. **Spinal mouse®**. Romênia: Spinal Mouse . 2017. Disponível em: <<http://spinalmouse.ro/en>>. Acesso em: 10 de nov. 2017.

SUZUKI, S. et al. Topological structural analysis of digitized binary images by border following. **Computer Vision, Graphics, and Image Processing**, Reston, v. 30, n. 1, p. 32–46, 1985.

TEIXEIRA, F.; CARVALHO, G. Reliability and validity of thoracic kyphosis measurements using flexicurve method. **Brazilian Journal of Physical Therapy**, São Carlos, v. 11, n. 3, p. 199–204, 2007.

TOMASI, C.; MANDUCHI, R. Bilateral filtering for gray and color images. In: SIXTH INTERNATIONAL CONFERENCE ON COMPUTER VISION, 6., 1998, Bombay. **Anais...** Bombay: IEEE. 1998. p. 839–846.

ZHANG, T.; SUEN, C. Y. A fast parallel algorithm for thinning digital patterns. **Communications of the ACM**, Nova York, v. 27, n. 3, p. 236–239, 1984.