

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

IGOR CATANEO SILVEIRA

**ESTUDO DE TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS DA
MUCOSA INTESTINAL**

TRABALHO DE CONCLUSÃO DE CURSO

**PONTA GROSSA
2015**

IGOR CATANEO SILVEIRA

**ESTUDO DE TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS DA
MUCOSA INTESTINAL**

Trabalho de Conclusão de Curso apresentada como requisito parcial à obtenção do título de Bacharel em Ciência da Computação, do Departamento Acadêmico de Informática, da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dra. Helyane B. Borges
Co-orientador: Prof. Msc. Geraldo Ranthum.

PONTA GROSSA

2015



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Ponta Grossa

Diretoria de Graduação e Educação Profissional
Departamento Acadêmico de Informática
Coordenação do Curso Superior de Bacharelado em Ciência da
Computação
Curso Superior de Bacharelado em Ciência da Computação



TERMO DE APROVAÇÃO

ESTUDO DE TÉCNICAS DE SEGMENTAÇÃO DE IMAGENS DA MUCOSA INTESTINAL

por

IGOR CATANEO SILVEIRA

Este(a) Trabalho de Conclusão de Curso foi apresentado(a) em 21 de maio de 2015 como requisito parcial para a obtenção do título de Bacharel em Ciência da Computação. O(a) candidato(a) foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Helyane B. Borges
Prof.(a) Orientador(a)

Geraldo Ranthum
Membro titular

Erikson Freitas de Moraes
Membro titular

- O Termo de Aprovação assinado encontra-se na Coordenação do Curso –

AGRADECIMENTOS

Agradeço seja ao acaso ou seja a Deus por poder chegar até aqui sabendo que se eu fosse agradecer a todos que contribuíram para que este trabalho fosse feito, então este documento teria pelo menos o dobro de páginas.

Em especial para aqueles que me ajudaram tanto sem nem sermos da mesma família: Lin Jung Tang, Silvana Rocha e Luciane Rotta.

Genoi hoios essi.
(Horácio, Odas Píticas II)

RESUMO

SILVEIRA, Igor Cataneo. **Estudo de Técnicas de Segmentação de Imagens da Mucosa Intestinal**. 2015. 72 f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2015.

Estima-se que em 2035 o diabetes afetará 592 milhões de pessoas ao redor do mundo e em 2014 metade dos diabéticos não sabem que possuem esta desordem. Sabe-se na medicina que existe uma relação entre o tipo II desta doença e a hipertrofia da mucosa intestinal, mas não se sabe exatamente qual a natureza da ligação. Neste trabalho, técnicas de Processamento de Imagens de pré-processamento, detecção de bordas/segmentação e pós-processamento são usadas para segmentar os vilos – sendo os vilos a estrutura responsável por aumentar a área de absorção das paredes intestinais. As técnicas usadas são: Histograma, Mediana, Expansão de Contraste, Transformada Logarítmica, Filtro Laplaciano, Morfologia Matemática, Marr-Hildreth, Canny e Watershed. Estas técnicas são utilizadas em três diferentes abordagens: primeiramente, é utilizado apenas segmentação. Por segundo, pré-processamento e segmentação são combinados. Por fim, pré-processamento, segmentação e pós-processamento são combinados para comparar os resultados de cada abordagem. Os resultados mostram que a terceira abordagem tem melhores resultados, embora a imagem não seja segmentada completamente.

Palavras-chave: Processamento de Imagens. Detecção de Bordas. Diabetes. Mucosa Intestinal.

ABSTRACT

SILVEIRA, Igor Cataneo. **Study of Segmentation Techniques of Intestinal Mucosa Images**. 2015. 72 f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) - Federal Technology University - Parana. Ponta Grossa, 2015.

It is estimated that the diabetes will affect 592 million people around the world by the year 2035 and by the year of 2014 half of the diabetics do not know they have the disorder. At Medicine is known that there is relation between the type II of this disease and the hypertrophy of intestinal mucosa, but it is not exactly known what binds them. In the present paper, techniques of preprocessing, edge detection/segmentation and post-processing of Image Processing are used in order to segment the villus – being the villus the structure responsible for increasing the area available for absorption on the intestinal walls. The techniques used are: Histogram, Median, Contrast-Stretching, Logarithmic Transformation, Laplacian Filter, Mathematical Morphology, Marr-Hildreth, Canny and Watershed. These techniques are used in three different approaches: firstly, it is used only segmentation. Secondly, preprocessing and segmentation are combined. Finally, preprocessing, segmentation and post-processing are combined in order to compare the result in each approach. The results show that the third approach have better results, although the image is not completely segmented.

Keywords: Image Processing. Edge Detection. Diabetes. Intestinal Mucosa.

LISTA DE FIGURAS

Figura 1 – Exemplo de imagem gerada por endoscopia magnificada 100 vezes.....	14
Figura 2 – Recorte de uma parte da Figura 1.....	14
Figura 3 – Ponto 1 indica o topo do vilo, de 1 a 2 representa a altura.	18
Figura 4 – Exemplo de matriz.....	18
Figura 5 – Destaque das linhas da figura 1	19
Figura 6 – Destaque das colunas da figura 1	19
Figura 7 – Imagem RGB	22
Figura 8 – Figura 7 em 256 tons de cinza	22
Figura 9 – Histograma da Figura 8.....	23
Figura 10 – Histograma equalizado da Figura 8.....	24
Figura 11 – Figura 8 com histograma equalizado	24
Figura 12 – Aplicação do filtro da mediana: (a) Imagem original; (b) Imagem em tons de cinza; (c) imagem b com ruído sal e pimenta; (d) resultado da aplicação do filtro da mediana sobre a imagem c	25
Figura 13 – Figura 8 com contraste de valor igual a 10	27
Figura 14 – À direita: resultante da aplicação da transformada logarítmica sobre o Espectro de Fourier à esquerda.....	28
Figura 15 – Exemplos de filtros laplacianos	28
Figura 16 – (A) resultado do filtro; (B) imagem aguçada	29
Figura 17 – (A) triangulo; (B) linha; (C) cruz; (D) quadrado.....	30
Figura 18 – Exemplos de dilatação e erosão	31
Figura 19 – (a) Imagem original; (b) Gradiente morfológico usando quadrado 3 por 3 como ES.....	33
Figura 20 – Detecção de borda do Algoritmo Canny.....	35
Figura 21 – Primeira abordagem.....	39
Figura 22 – Segunda abordagem.....	39
Figura 23 – Terceira abordagem	40
Figura 24 – (A) Recorte de uma parte da Figura 1. (B) Mesmo recorte em 256 tons de cinza	41
Figura 25 – Utilizando raio igual a: (A) 1 (B) 2 (C) 3 (D) 4.....	42
Figura 26 – Utilizando matriz de dimensão igual a: (A)3x3 (B)4x4 (C)8x8 (D)10x10.....	43
Figura 27 – $\sigma = 2$, valores de limiar: (A)0,0 (B)0,002 (C)0,0035 (D)0,005.....	44
Figura 28 – limiar = 0,002, $\sigma =$ (A)1 (B)1,5 (C)2,25 (D)3.....	45
Figura 29 - $L = 0,05$; $H = 0,3$; (A) $\sigma = 2$ (B) $\sigma = 4$ (C) $\sigma = 5$ (D) $\sigma = 6$	46
Figura 30 – aplicação do Watershed.....	47
Figura 31 – Histograma da imagem padrão em tons de cinza.....	48
Figura 32 – Histograma equalizado da imagem padrão em tons de cinza.....	49
Figura 33 – Imagem resultante do histograma equalizado.....	49

Figura 34 – Resultado da aplicação do algoritmo de (A) Canny (B) Marr-Hildreth (C) Morfologia Matemática (D) Watershed sobre a Figura 33.	51
Figura 35 – (A) Resultado da primeira abordagem (B) imagem resultante utilizando mediana como pré-processamento.	52
Figura 36 – limiar = 0,002 e $\sigma = 2$, (A) sem mediana, (B) com mediana.	53
Figura 37 – $L = 0,05$; $H = 0,3$; $\sigma = 4$; (A) sem mediana, (B) com mediana.	54
Figura 38 – (A) sem mediana, (B) com mediana sem auxiliares (C) com mediana e auxiliares.	54
Figura 39 – (A) Imagem original (B) coeficiente = 25 (C) coeficiente = 50 (D) coeficiente = 100.	55
Figura 40 – $L = 0,05$; $H = 0,3$; $\sigma = 4$; (A) sem pré-processamento (B) coeficiente = 25 (C) coeficiente = 50 (D) coeficiente = 100.	56
Figura 41 – Resultado do (A) Canny, parâmetros: $L = 0,05$; $H = 0,3$ e $\sigma = 4$. (B) Marr-Hildreth, parâmetros: limiar = 0,002 e $\sigma = 2$. (C) MM, como ES uma matriz 3x3. (D) Watershed. Imagem pré-processada usando aumento de contraste com coeficiente = 50.	57
Figura 42 – Transformada Logarítmica com coeficiente (A) 1 (B) 1.5. (C) 2 (D) 2.5.	58
Figura 43 – (A) Resultante da aplicação do Filtro Laplaciano 3x3 da Figura 15 (B) Aplicação do Filtro Laplaciano 5x5 da Figura 15 (C) Imagem com as bordas aguçadas.	59
Figura 44 – Imagem pré-processada com Filtro Laplaciano, resultado do algoritmo (A) Canny parâmetros: $L = 0,05$; $H = 0,3$ e $\sigma = 4$. (B) Marr-Hildreth: limiar = 0,002 e $\sigma = 2$. (C) Morfologia Matemática, elemento estruturante uma matriz 3x3. (D) Watershed.	60
Figura 45 – Em destaque as áreas de interesse (A) Imagem original em 256 tons de cinza. (B) Resposta do algoritmo de Canny sem pré-processamento. (C) Resposta de Canny com aplicação da Equalização de Histograma.	61
Figura 46 – Em destaque as áreas de interesse (A) Imagem original em 256 tons de cinza. (B) Resposta do algoritmo de Canny sem pré-processamento. (C) Resposta de Canny com aplicação do aumento de contraste.	62
Figura 47 – Em destaque as áreas de interesse (A) Imagem original em 256 tons de cinza. (B) Resposta do algoritmo de Canny sem pré-processamento. (C) Resposta de Canny com aplicação do Filtro Laplaciano.	63
Figura 48 – Resultado da dilatação aplicada à segmentação através de MM sendo pré-processada por (A) Expansão de Contraste. (B) Equalização de Histograma. (C) Filtro Laplaciano.	64
Figura 49 – Resultado da dilatação aplicada à segmentação através de Marr-Hildreth sendo pré-processado por (A) Expansão de Contraste. (B) Equalização de Histograma. (C) Filtro Laplaciano.	64
Figura 50 – Resultado da dilatação aplicada à segmentação do algoritmo de Canny sendo pré-processado por (A) Equalização de Histograma. (B) Expansão de Contraste. (C) Filtro Laplaciano.	65
Figura 51 – Resultado da dilatação aplicada à segmentação através de Marr-Hildreth sendo pré-processado por (A) Expansão de Contraste. (B) Equalização de Histograma. (C) Filtro Laplaciano.	65
Figura 52 – Watershed (A) sem erosão (B) com erosão.	66

Figura 53 – Evolução dos resultados (A) segmentação sem pré nem pós processamento (B) pré-processada (C) pré e pós processada67

LISTA DE SIGLAS

PI	Processamento de Imagens
ES	Elemento Estruturante
MM	Morfologia Matemática

SUMÁRIO

1 INTRODUÇÃO	12
1.1 PROBLEMA	13
1.2 JUSTIFICATIVA	15
1.3 OBJETIVO	15
1.3.1 Objetivo Geral	15
1.3.2 Objetivos Específicos	16
2 REFERENCIAL TEÓRICO	17
2.1 MUCOSA INTESTINAL E O DIABETES	17
2.2 IMAGEM DIGITAL	18
2.3 PROCESAMENTO DE IMAGENS DIGITAIS	20
2.4 TÉCNICAS DE PROCESSAMENTO DE BAIXO NÍVEL	20
2.4.1 Pré-processamento	21
2.4.1.1 Histograma	21
2.4.1.2 Mediana	24
2.4.1.3 Expansão de Contraste (<i>Contrast-Stretching</i>)	26
2.4.1.4 Transformada Logarítmica	27
2.4.1.5 Filtro Laplaciano	28
2.4.2 Pós-processamento	29
2.4.2.1 Morfologia Matemática	30
2.5 TÉCNICAS DE PROCESSAMENTO DE MÉDIO NÍVEL	31
2.5.1 Detecção de Bordas e Segmentação	32
2.5.2 Morfologia Matemática	33
2.5.3 Marr-Hildreth	33
2.5.4 Canny	34
2.5.5 Watershed	35
2.6 TRABALHOS RELACIONADOS	36
3 EXPERIMENTAÇÃO	38
3.1 AQUISIÇÃO DAS IMAGENS	38
3.2 FERRAMENTAS	38
3.3 METODOLOGIA	38
4 RESULTADOS	41
4.1 PRIMEIRA ABORDAGEM	41
4.2 SEGUNDA ABORDAGEM	48
4.3 TERCEIRA ABORDAGEM	63
5 CONCLUSÃO	68
5.1 TRABALHOS FUTUROS	69
REFERÊNCIAS	70

1 INTRODUÇÃO

O diabetes é uma doença que afeta uma grande parte da população mundial. A estimativa é que 592 milhões de pessoas do mundo serão portadoras da doença no ano de 2035. Um dos fatores de interesse é a questão de comumente a pessoa não saber que é afetada pela doença, como no sudeste da Ásia, onde 50% dos diabéticos não sabem que possuem essa desordem em seu metabolismo (INTERNATIONAL DIABETES FEDERATION, 2013).

Operações médicas estão cada vez mais à procura de diagnósticos mais precisos. Para alcançar tal objetivo os médicos dispõem de uma ampla gama de técnicas geradoras de imagem, a saber: tomografia, endoscopia, etc. (DUNCAN; AYACHE, 2000).

Processamento de Imagens usando computadores é, no momento, um dos campos que mais cresce em ciência da computação. Seu desenvolvimento se dá fundamentalmente por causa da produção de equipamentos eletrônicos menores, mais potentes e mais baratos, os quais permitem maiores investigações nesse campo (GONZALEZ; WOODS, 2010).

Esta melhora criou a tendência às imagens digitais, acarretando em exames como os de raio-X poderem ser gerados e processados via computador (GONZALEZ et al., 2003).

As imagens geradas por computador, por consequência, se tornaram uma fonte rica de informação, dando ao profissional condições para fazer diagnósticos mais precisos em um tempo reduzido.

O diabetes está entre as doenças que podem ser diagnosticadas através de imagens. Apoiado por estudos de Miller et al. (1977), Verdam et al. (2011) e reforçado por Karlsson et al. (2013), Rodrigues (2012) afirma que é um fato que a hipertrofia da mucosa intestinal está ligada com o diabetes tipo II. Embora não seja clara qual é a ligação e quais são suas características, há evidências que os vilos - estruturas presentes na mucosa - incham e se tornam maiores ou mais compridos.

Assim, a identificação de um padrão da estrutura da mucosa intestinal (SILVEIRA et al., 2014) capaz de identificar uma pessoa com diabetes, ou se a mesma tem pré-disposição para a doença, seria de grande importância para toda a comunidade científica. Uma das maneiras de tentar auxiliar nesse processo seria

extrair características (atributos) – tais como largura e altura – das imagens e depois aplicar algoritmos de aprendizagem de máquina para classificar tais características. Porém, para se chegar nesta etapa é necessário, primeiramente, realizar um pré-processamento, identificação das bordas e pós-processamento na imagem analisada.

O presente trabalho de conclusão de curso tem como objetivo estudar e testar técnicas de pré-processamento, identificação das bordas e pós-processamento. Sendo assim, o desenvolvimento do trabalho poder vir a contribuir com a área médica e com a de processamento de imagens: primeiramente, podendo ser utilizado por algoritmos que visem identificar a relação diabetes-mucosa intestinal; em segundo lugar, como método auxiliar – aos exames laboratoriais – na identificação de uma doença que é um problema mundial; uma boa segmentação seria mais um passo para a área de processamento de imagens.


1.1 PROBLEMA

Segundo a International Federation of Diabetes (2014) uma a cada 12 pessoas no mundo tem diabetes; a cada 7 segundos uma pessoa morre por causa desta doença; nos dados apresentados em 2013 constava que no sudeste asiático 50% dos diabéticos não sabiam ter esta doença, os dados de 2014 já relatam que esse 50% não está mais restrito e é válido para o mundo todo.

Sendo assim, fica evidente a abrangência do mal do diabetes, o qual, como apontam pesquisadores, está ligado à hipertrofia da mucosa intestinal onde os vilos – estruturas semelhantes aos dedos – incham e se tornam maiores ou mais compridos.

Imagens da mucosa intestinal podem ser obtidos através de uma série de exames, entre eles, o de endoscopia, o qual quando magnificado 100 vezes gera imagens como as apresentadas na Figura 1, mas neste trabalho será utilizado apenas um fragmento da imagem toda, tal como a Figura 2.

Como a imagem não tem muito contraste, uma vez que todos os elementos dela são da mesma cor, então o trabalho de segmentação – separar as partes constituintes da imagem – foge da trivialidade. Por isso, o objetivo do trabalho é encontrar uma combinação de técnicas de Processamento de Imagens que melhor se adapte para identificar os vilos de imagens da mucosa intestinal.



**Figura 1 – Exemplo de imagem gerada por endoscopia magnificada 100 vezes.
Fonte: PRIMED (2013).**



**Figura 2 – Recorte de uma parte da Figura 1.
Fonte: adaptado de PRIMED (2013).**

1.2 JUSTIFICATIVA

Este trabalho é a etapa inicial de um projeto que visa ser capaz de classificar uma dada imagem da mucosa intestinal como pertencente a uma pessoa diabética ou saudável. Para isso, primeiramente é necessário ter uma base de dados de características, as quais são extraídas através do objeto segmentado da imagem.

Sendo assim, com o aumento da precisão da segmentação – ato de separar uma zona de interesse de uma imagem do restante dela (GONZALEZ et al., 2003) – há um ganho na confiabilidade dos valores da base, acarretando em uma classificação mais precisa.

Se bem segmentados os vilos da imagem, então torna-se possível extrair dados sobre eles, tais como: altura, largura e outros dados derivados destes, como por exemplo, altura média, largura média, área, área média, entre outros.

Apesar das imagens da mucosa intestinal serem retiradas através de métodos mais invasivos – endoscopia e/ou colonoscopia – para o paciente, ela se justifica pelo fato de ser um método auxiliar aos outros já existentes, não os substituindo. Além disto, a detecção da pré-disposição da diabetes através da hipertrofia da mucosa intestinal pode indicar a doença antes do exame de sangue, uma vez que este indica apenas quando já há o problema. Assim, espera-se que com a identificação de um padrão de imagens com hipertrofia na mucosa intestinal possa auxiliar os 50% que não sabem que tem o diabetes assim como a prevenir o desenvolvimento da doença.

1.3 OBJETIVO

Neste tópico serão abordados o objetivo geral e os objetivos específicos do trabalho.

1.3.1 Objetivo Geral

O objetivo geral é estudar técnicas de segmentação de imagens da Mucosa Intestinal através de Processamento de Imagens.

1.3.2 Objetivos Específicos

Os objetivos específicos são:

- Selecionar e aplicar técnicas de Pré-processamento;
- Selecionar e aplicar algoritmos de segmentação;
- Selecionar e aplicar técnicas de pós-processamento;
- Combinar diferentes técnicas;
- Comparar os resultados das técnicas combinadas.

2 REFERENCIAL TEÓRICO

Nesta seção serão abordados conceitos que serão necessários para o entendimento da pesquisa. O objetivo é apresentar definições e características das seguintes técnicas de processamento de imagem: Expansão de Contraste, Canny, Watershed, Morfologia Matemática, Histograma, Marr-Hildreth, Mediana, Filtro Laplaciano e Transformada Logarítmica. As técnicas escolhidas podem auxiliar a segmentação de imagens da mucosa intestinal, sobre a qual também será brevemente discorrido enfatizando sua ligação com o diabetes. Para abordar as técnicas é necessário primeiramente a definição de o que é uma imagem digital, para depois estender para a área Processamento de Imagens Digitais.

2.1 MUCOSA INTESTINAL E O DIABETES

O diabetes mellitus é uma doença que no ano de 2013 afetava 382 milhões de pessoas ao redor do mundo (INTERNATIONAL DIABETES FEDERATION, 2013), este mal é dividido em quatro tipos, a saber: diabetes mellitus 1 e 2, gestacional e outros casos específicos (WHO, 2006). O caso de interesse para este trabalho é o do tipo 2, que coincide em ser o que afeta a maior parte da população de diabéticos. Segundo Kahn (2003), neste caso o diabético não consegue produzir insulina suficiente ou seu corpo não mais reage devidamente. Estudos como os de Miller et al. (1977), Verdam et al. (2011) e, mais recentemente, Karlsson et al. (2013) apontam relações entre o diabetes deste tipo e a mucosa intestinal.

A mucosa intestinal é responsável pela absorção de nutrientes e água para a célula. Os responsáveis por aumentar a área de absorção da mucosa são os vilos, estruturas que tem formato parecido com o de dedos, conforme mostra a Figura 3 – o ponto 1 indica o topo do vilos, enquanto sua altura é denotada do ponto 1 ao 2. Estes vilos são a área de interesse que deseja-se segmentar o melhor possível. Por sua semelhança com os dedos, eles possuem então altura, largura, área e outras propriedades que podem ser analisadas através de processamento de imagens (RODRIGUES, 2012; MATHERS, 1998).




Figura 3 – Ponto 1 indica o topo do vilão, de 1 a 2 representa a altura.
 Fonte: CRUZ (2013) apud PIRES et.al (2003)

2.2 IMAGEM DIGITAL

Imagens são armazenadas através de matrizes, um exemplo de matriz é dado na Figura 4.

$$\begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix}$$

Figura 4 – Exemplo de matriz
 Fonte: Autoria Própria

Matrizes possuem linhas e colunas, a exemplificada na Figura 4 possui duas linhas e duas colunas. As duas linhas dessa matriz estão destacadas na Figura 5 através das letras gregas α e β , correspondendo respectivamente à primeira e

segunda linha. Enquanto as colunas estão destacadas na Figura 6, sendo o destacado pela letra γ a primeira coluna e a segunda coluna através de δ .

Dada uma matriz M , um elemento contido nela pode ser mapeado através de uma relação envolvendo sua linha e sua coluna. Por exemplo, $M(1,2)$ corresponde ao elemento que está na primeira linha e segunda coluna, ou segunda coluna da primeira linha, as duas leituras são possíveis. Na matriz dada nas Figuras 4, 5 e 6 o elemento $M(1,2)$ é o 2 (dois) (BOLDRINI et al.,1980).




Figura 5 – Destaque das linhas da figura 1
Fonte: Autoria Própria




Figura 6 – Destaque das colunas da figura 1
Fonte: Autoria Própria

Uma imagem será então definida através de uma função bidimensional $f(x,y)$ para acessar o elemento presente na coluna y da linha x de uma matriz. Os elementos da matriz para qualquer par de coordenadas x e y são chamados de intensidades ou mesmo de níveis de cinza. Uma imagem digital possui dimensão limitada, possuindo assim uma quantidade finita de intensidades, cada qual com sua localização e valor específico. As intensidades que compõem uma imagem podem assumir várias nomenclaturas, a utilizada mais comumente é pixels (GONZALEZ; WOODS, 2010). Resumidamente, um pixel possui localização e intensidade, tendo essa intensidade um valor associado a ela.

2.3 PROCESAMENTO DE IMAGENS DIGITAIS

Quanto à sua aplicação, o processamento de imagens (PI) geradas por computador possui uma abrangência maior do que as que podem ser captadas pelo olho humano, uma vez que este é limitado pelo espectro eletromagnético. As geradas por computador podem vir de ultrassom, microscopia eletrônica, entre outros. Sendo assim, sua aplicação é diversa e variada (GONZALEZ et al, 2003).

Por outro lado, não há uma definição de qual parcela da Ciência da Computação é domínio do Processamento de Imagens. Gonzalez e Woods (2010) dizem: “Não existe um acordo geral entre os autores em relação ao ponto em que o processamento de imagens termina e outras áreas relacionadas, como a análise de imagens e a visão computacional, começam”. Apesar disso, eles propõem um paradigma dividido em três: processos de alto, médio e baixo nível. Onde o primeiro nível – o baixo – tanto a entrada quanto a saída do processo são imagens, ou seja, corresponde às operações elementares, filtros para destacar bordas ou para suavizar a imagem, entre outros. O médio diferencia-se da anterior pela saída, que agora são atributos extraídos das imagens, como, por exemplo, as bordas de um objeto. O último deles seria mais próximo do humano, atribuindo um significado a um conjunto de objetos.

Segundo Marques Filho e Vieira Neto (1999) o PI viabiliza duas tarefas: primeiramente a melhora nas informações presentes em uma dada imagem para auxiliar a visão humana; e, por último, dada uma cena, o computador analisá-la automaticamente.

2.4 TÉCNICAS DE PROCESSAMENTO DE BAIXO NÍVEL

As técnicas de processamento de baixo nível se caracterizam pelo fato de que tanto a entrada como a saída são imagens. Entre as técnicas pertencentes a esse nível estão: Expansão de Contraste, Histograma, Mediana, Filtro Laplaciano, Transformada Logarítmica e algumas operações de Morfologia Matemática. É possível fazer uma subdivisão dentro dessas operações, a saber, entre técnicas de pré e pós-processamento. Ao pertencer a um grupo, não necessariamente ela não

pertencerá ao outro, sendo assim, algumas técnicas pertencem às duas divisões, mas independente de quando aplicadas, seu objetivo é o mesmo.

2.4.1 Pré-processamento

Por pré-processamento entende-se o conjunto de técnicas que são aplicadas antes da segmentação – etapa que visa identificar os objetos que fazem parte da imagem –, por isso são chamadas de técnicas de pré-processamento. A este grupo pertencem: Histograma, Mediana, Expansão de Contraste, Transformada Logarítmica e o Filtro Laplaciano. O objetivo destas operações é destacar alguma qualidade na imagem.

2.4.1.1 Histograma

O histograma de uma imagem representa a ocorrência de cada intensidade presente na dada imagem. Sendo assim, a variação vai de 0 até $L-1$, sendo L o número de tons de cinza do formato da imagem (GONZALEZ; WOODS, 2010).

Também é possível fazer histogramas de imagens coloridas, neste caso haverá um histograma para cada canal da imagem, por exemplo, uma imagem RGB possui três canais, o vermelho – do inglês *red* –, o azul – *blue* – e o verde – *green*. A Figura 7 apresenta uma imagem RGB, a Figura 8 apresenta a mesma imagem convertida para 256 tons de cinza e a Figura 9 apresenta o histograma da em tons de cinza.

Uma imagem que possua grande concentração de pixels com valores próximos de 0 será uma imagem predominantemente escura. O contrário também será verdadeiro: uma imagem com alta concentração de pixels próximos de 255 será uma imagem clara. Caso os valores estejam concentrados em uma pequena faixa diz-se que a imagem possui pouco ou baixo contraste; se uma concentração em uma faixa estreita determina um contraste baixo, uma distribuição ao longo de todo eixo dos tons de cinza faz com que a imagem tenha um alto contraste (MARQUES FILHO; VIEIRA NETO, 1999).



Figura 7 – Imagem RGB
Fonte: Autoria própria.



Figura 8 – Figura 7 em 256 tons de cinza
Fonte: Autoria própria.

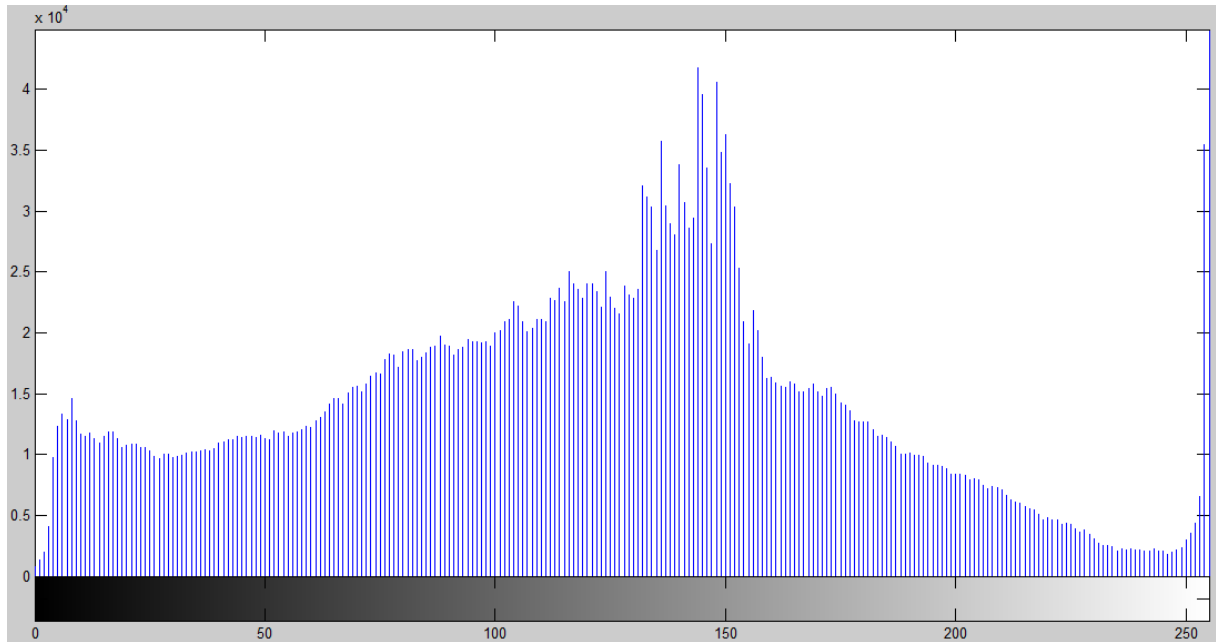


Figura 9 – Histograma da Figura 8
Fonte: Autoria própria.

Através dessa análise vê-se que o histograma é útil para extrair informações sobre uma dada imagem. Além disso, há operações que são feitas baseadas nele, como a Equalização de Histograma, uma técnica que visa redistribuir os pixels de uma imagem obtendo desta vez um histograma mais balanceado. Sua definição e explicação matemática podem ser encontradas em maiores detalhes em Gonzales e Woods (2010,p.79), e o resultado de sua operação é o mapeamento de um novo valor – chamado de s – para todas as k intensidades presentes na imagem original através da Equação 1.

$$s(k) = \frac{(L - 1)}{MN} \sum_{j=0}^k n(j) \quad (1)$$

Em que L corresponde ao número de tons de cinza da imagem, MN é a multiplicação do número de linhas pelo número de colunas e $n(j)$ é o número de vezes que determinado pixel apareceu dividido por MN .

A Figura 10 exhibe o histograma equalizado da Figura 8, enquanto a Figura 11 corresponde à imagem com histograma equalizado.




Figura 10 – Histograma equalizado da Figura 8
Fonte: Autoria própria.



Figura 11 – Figura 8 com histograma equalizado
Fonte: Autoria própria.

2.4.1.2 Mediana

Em conformidade com Marques Filho e Vieira Neto (1999), Gonzalez et al. (2003) afirmam que este filtro é muito útil para reduzir ruídos do tipo sal e pimenta – ou seja, os ruídos que parecem como se grãos de sal e pimenta tivessem sido

espalhados aleatoriamente pela imagem. Sua vantagem em relação a filtros de mesma função, como o da média, é que o abordado neste tópico não tem perda das bordas.

Um exemplo da aplicação desta técnica é mostrado na Figura 12, onde é exibida a imagem original (a), ela em preto e branco (b), a aplicação do ruído sal e pimenta sobre a preto em branco (c), e a imagem resultante quando aplicado o filtro da mediana sobre a imagem da letra anterior (d).




Figura 12 – Aplicação do filtro da mediana: (a) Imagem original; (b) Imagem em tons de cinza; (c) imagem b com ruído sal e pimenta; (d) resultado da aplicação do filtro da mediana sobre a imagem c

Fonte: Autoria Própria

Esta técnica é aplicada tendo em vista a vizinhança de um pixel. Define-se vizinhança como os elementos que estão ao lado, exemplos de vizinha são vizinhança-4 e vizinhança-8. Um dado pixel ocupa a posição $M(x,y)$, seus 4 vizinhos são: o vizinho da direita: $M(x,y+1)$; o de cima: $M(x-1,y)$; o da esquerda: $M(x,y-1)$; e também o de baixo: $M(x+1,y)$. No caso da vizinhança de 8, além dos 4 elencados

anteriormente, é necessário também considerar os pixels que estão na diagonal, a posição deles deve ser facilmente identificável seguindo a lógica anterior: $M(x+1,y-1)$ e $M(x+1,y+1)$ são os das diagonais inferiores, $M(x-1,y-1)$ e $M(x-1,y+1)$ são os das superiores.

O processo usado por essa técnica é: sendo N um conjunto contendo o valor de um pixel P e dos elementos em sua vizinhança V , N possuirá $V+1$ elementos, ou seja, $|N| = V+1$. Os valores de N são ordenados em ordem crescente de intensidade. A mediana do conjunto N é o elemento que ocupe a posição $|N|/2$ do próprio conjunto, o valor da mediana é então atribuído ao pixel P .

Duas observações fazem-se necessárias neste ponto. A primeira é de que $|N|$ pode ser par ou ímpar. No caso de ser ímpar, o número é truncado para cima; caso seja par, o valor de P será a média entre a soma de $|N|/2$ com o elemento à sua direita. Uma definição com maior rigor matemático pode ser encontrado em Dougherty (1994).

Em segundo lugar é que a atividade de ordenar os elementos pode ser custosa computacionalmente. Devido a isso foi criado por Pratt et al. (1985) o filtro da pseudomediana, o qual, segundo os próprios autores: “possui muito das características da mediana, mas é computacionalmente mais eficientemente”.

2.4.1.3 Expansão de Contraste (*Contrast-Stretching*)

Essa técnica necessita de um parâmetro, que será um ponto de referência chamando M : a operação fará todos os pontos menores que M se estreitarem em uma faixa, a qual será mais escura, e os pontos que forem maiores que M se estreitarão numa faixa mais clara. Deste modo a imagem terá um contraste maior.

A fórmula matemática pode ser encontrada em Gonzalez et al. (2003). Percebe-se que a transformada não é linear, e que o coeficiente determina a inclinação da curva, sendo então o coeficiente o principal valor da equação, quão maior ele for, maior será o contraste. Um ponto de interesse é que em seu extremo, essa operação pode transformar uma imagem em tons de cinza em uma imagem binária que possui apenas os dois extremos, branco ou preto. Um exemplo mostrando a aplicação desta técnica é mostrado na Figura 13, a qual apresenta a Figura 8 com seu contraste aumentado utilizando um coeficiente de valor igual a dez.



**Figura 13 – Figura 8 com contraste de valor igual a 10
Fonte: Autoria Própria.**

2.4.1.4 Transformada Logarítmica

Combinando o Expansão de Contraste com a Transformada Logarítmica obtém-se um conjunto de ferramentas básicas para manipulação dinâmica da banda (GONZALEZ et al., 2003). Entende-se por banda, neste contexto, a faixa onde estão distribuídas as intensidades de uma imagem.

A principal utilização desta técnica é comprimir essa banda com a finalidade de exibir melhor informações no monitor. Como citado por Gonzalez et al (2003), há casos em que a imagem pode ter uma variação de mais de sete casas decimais, fazendo com que não seja possível exibir a imagem com riqueza de detalhes, uma vez que os monitores comportam normalmente números de até 8 bits.

Utilizando o menor número com sete casas decimais que seja potência de dois, a saber, o 1048576, e logaritmo na base 2, chega-se ao dado de que usa 20+1 bits para sua representação. Esse número pode ser reduzido de 21 para aproximadamente 14 bits utilizando esta transformada, havendo uma perda menor de detalhes quando exibido no monitor.

A imagem apresentada na Figura 14 mostra a aplicação desta técnica sobre um Espectro de Fourier.




Figura 14 – À direita: resultante da aplicação da transformada logarítmica sobre o Espectro de Fourier à esquerda.

Fonte: (GONZALEZ; WOODS, 2003)

2.4.1.5 Filtro Laplaciano

Este filtro tem a função de destacar bordas (MARQUES FILHO; VIEIRA NETO, 1999). Sua criação se dá através de uma matriz cuja soma dos elementos é igual a zero. Alguns exemplos de Filtro Laplaciano são mostrados na Figura 15.

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad \begin{bmatrix} -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & 24 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 \end{bmatrix}$$

Figura 15 – Exemplos de filtros laplacianos
Fonte: (MARQUES FILHO; VIEIRA NETO, 1999)


Como algumas operações para eliminar ruídos normalmente prejudicam as bordas da imagem, normalmente operadores como o Laplaciano são utilizados anteriormente para aguçar as bordas. A operação do filtro funciona semelhante à da vizinhança da Mediana, porém agora a vizinhança é maior, e ao invés de o valor

central receber a mediana entre ele e os vizinhos, será necessário realizar mais passos. Portanto é necessário manter em foco que está se lidando com um pixel P , esse pixel P será multiplicado pelo valor central do filtro, resultando em x_1 ; o vizinho da direita de P será multiplicado pelo valor à direita do elemento central do filtro, seu resultado será x_2 ; e assim será feito para todos os elementos do filtro.

Para um filtro 3x3 como o apresentado na Figura 15 à esquerda, haverá x_1, x_2, \dots, x_9 . Então soma-se todos esses valores e atribui o resultado ao pixel P , este processo chama-se convolução discreta (BOVIK, 2009; GONZALEZ; WOODS, 2010; MARQUES FILHO; VIEIRA NETO, 1999).

A aplicação do filtro gera uma imagem contendo as bordas da que foi usada como entrada. Esta é então subtraída ou adicionada à original, resultando em uma imagem com as bordas aguçadas. Será subtraída se o elemento central do filtro for negativo e somada caso seja positivo.

Um exemplo é dado na Figura 16, onde para não prejudicar a qualidade das imagens foi omitida a original, que é a mesma mostrada na Figura 12. Nessa figura, é possível notar o aguçamento na região das telhas do teto.



(A)



(B)

Figura 16 – (A) resultado do filtro; (B) imagem aguçada
Fonte: Autoria própria.

2.4.2 Pós-processamento

Neste tópico será abordado o conjunto de operações que podem ser utilizadas posteriormente à segmentação. Vale ressaltar que algumas técnicas que foram

explicadas no tópico anterior podem também ser utilizadas como pós-processamento, assim como as aqui explicadas podem, em alguns casos, servir como pré-processamento. Serão explanadas as operações de Morfologia Matemática que comumente são utilizadas nesta etapa.

2.4.2.1 Morfologia Matemática

Este conjunto de aplicações, propostas inicialmente por Serra (1982), tem analogia com a morfologia da biologia, porém a Morfologia Matemática (MM) tem sua aplicação sobre as estruturas matemáticas que compõem uma imagem. Para tal é utilizado teoria dos conjuntos. Estas técnicas podem ser usadas em um grande número de aplicações, as citadas a seguir são utilizadas usualmente para realce ou filtragem. Os elementos necessários para essas operações são dois: uma imagem e um elemento estruturante (ES), sendo este o elemento principal da MM, pois é através de uma estrutura matemática já conhecida e definida que as desconhecidas da imagem serão encontradas (GONZALEZ; WOODS, 2010; MARQUES FILHO; VIEIRA NETO, 1999). Exemplos de elementos estruturantes são apresentados na Figura 17, o elemento central está marcado por um ponto.




Figura 17 – (A) triângulo; (B) linha; (C) cruz; (D) quadrado
Fonte: Autoria própria.

(A) Dilatação normalmente representada pelo símbolo \oplus , a operação se apresenta da seguinte forma: Imagem \oplus ES. O primeiro passo da dilatação é fazer a reflexão do ES em torno de sua origem, seguindo da translação dessa reflexão por x . Uma dilatação de A é o conjunto de todos os deslocamentos possíveis de x tal que a

união de A com o ES seja um elemento diferente de zero. O resultado da dilatação é a imagem “engordada” por um dado elemento. A definição matemática mais rigorosa pode ser encontrada em Gonzalez e Woods (2010). A representação gráfica torna mais intuitivo o conceito, portanto exemplos são apresentados na Figura 18 à esquerda.

(B) Erosão é a operação contrária à dilatação, a qual “diminui” os elementos da imagem, seu símbolo é \ominus . Os passos da operação são os mesmos descritos na dilatação, diferenciando-se pelo conjunto que define a operação, nesta são os deslocamentos que estão contidos em A . Uma definição mais rigorosa pode ser encontrada em Gonzalez e Woods (2010). Exemplos desta operação são apresentados na Figura 18 à direita.




Figura 18 – Exemplos de dilatação e erosão
Fonte: (MARQUES FILHO; VIEIRA NETO, 1999)

2.5 TÉCNICAS DE PROCESSAMENTO DE MÉDIO NÍVEL

Neste tópico serão abordadas as técnicas que possuem a característica de receberem uma imagem como entrada e retornarem as bordas desta como saída.

Entre as técnicas de processamento de médio nível estão o algoritmo de Canny, Watershed, Marr-Hildreth e o gradiente morfológico via MM.

Estas técnicas possuem funcionamento matemático complexo, o qual não será detalhado profundamente, ao invés disto é apresentado suas motivações e/ou inspirações. Sabendo, porém, que esta parte é de grande importância para outros trabalhos, para não haver uma lacuna nesta parte teórica, será indicado onde pode-se encontrar explicações na literatura sobre esse tema.

Antes de discorrer sobre as técnicas faz-se necessário uma diferenciação conceitual entre dois termos: Detecção de Bordas e Segmentação

2.5.1 Detecção de Bordas e Segmentação

Segmentação é uma das principais operações em análises de imagem. Conforme Bovik (2009), existem 2 tipos de bordas físicas: (1) o conjunto de pontos que está entre duas ou mais regiões diferentes e (2) onde há mudança abrupta em uma superfície. Porém em imagens o conceito de borda não é o mesmo do das físicas. Em imagens este conceito depende da aplicação, mas genericamente pode ser dito que é o limite, as fronteiras, que separam regiões adjacentes que tenham alguma característica diferente (BOVIK, 2009). É importante atentar ao fato de não existir um detector de bordas que seja capaz de identificar com precisão as bordas de qualquer imagem.

Um outro ponto importante que costuma confundir por motivos semânticos é a diferenciação: segmentação e detecção de bordas. Conforme elencado na justificativa, segmentar é separar uma região de interesse. Ao fim desse processo haverão as bordas da região, mas para chegar até elas não necessariamente é utilizado algum algoritmo de detecção de bordas. Sendo assim, uma detecção de borda segmenta, mas uma segmentação não necessariamente é feita utilizando detecção de bordas, pois há outros métodos baseados em outros conceitos, por exemplo: a limiarização, que consiste em segmentar utilizando um valor, os pixels acima desse valor serão bordas. Outro exemplo é o crescimento de regiões, grupo ao qual pertence o Watershed, o qual será explicado nos próximos tópicos (GONZALEZ; WOODS, 2010).

2.5.2 Morfologia Matemática

É possível segmentar uma imagem utilizando-se de operações simples de MM, conforme apresentado na Figura 19, através do gradiente morfológico, ou seja, utilizando a diferença entre a dilatação e a erosão de uma mesma imagem obtém-se as bordas de uma determinada imagem (BOVIK, 2009; GONZALEZ; WOODS, 2010).



Figura 19 – (a) Imagem original; (b) Gradiente morfológico usando quadrado 3 por 3 como ES.
Fonte: (BOVIK, 2009)

O que pode ser expresso da seguinte forma, onde *Imagem* corresponde à imagem que se deseja segmentar:

$$A = \text{Imagem} \oplus \text{ES}$$

$$B = \text{Imagem} \ominus \text{ES}$$

$$\text{Bordas} = A - B$$

2.5.3 Marr-Hildreth

Os primeiros detectores de borda funcionavam seguindo a lógica de filtros, semelhante a como foi explicado sobre o Filtro Laplaciano. Exemplos de detectores que funcionavam com essa lógica são: Prewitt (1970), Frei-Chen (1977), Sobel (1978).

O algoritmo de Marr-Hildreth (1980) foi um dos primeiros, conforme Gonzalez e Woods (2010) “a incorporar análises mais sofisticadas no processo de busca das bordas”, pelas crenças que tinham Marr e Hildreth (1980), a saber, de que os operadores deveriam poder ser escalonados para funcionar em qualquer escala, e, além disso, de que mudanças na intensidade geram ou um vale ou um pico na primeira derivada, enquanto na segunda derivada geram o cruzamento de zeros (MARR;HILDRETH, 1980; BOVIK, 2009; GONZALEZ; WOODS, 2010).

O algoritmo em questão possui 3 etapas, as quais podem ser descritas por:

1. Filtrar a imagem recebida por um filtro específico que suaviza a imagem e diminui os ruídos;
2. Tendo a imagem resultante da etapa 1, calcular o seu laplaciano para encontrar as bordas;
3. Encontrar os cruzamentos por 0 da imagem resultante da etapa 2.

2.5.4 Canny

Proposto por Canny (1986) é um algoritmo mais complexo do que os elencados anteriormente, porém, em geral, é superior aos anteriores (GONZALEZ; WOODS, 2010).

Usa, assim como o algoritmo de Marr-Hildreth, derivada de primeira e segunda ordem, porém ele tem outros 3 pilares: (1) número reduzido de erros: o criador assumiu que tanto as bordas detectadas que não existem quanto as que existem e não são detectadas são igualmente prejudiciais; (2) boa localização de bordas: distância entre as bordas detectadas e as verdadeiras deve ser a menor possível; por fim, (3) resposta única para cada borda: o algoritmo não deve detectar várias bordas que só tenham um pixel.

Gonzalez e Woods (2010) alegam que pode ser impossível achar uma solução fechada que satisfaça as três condições.

Uma definição matemática rigorosa do Algoritmo de Canny pode ser encontrada em Gonzalez e Woods (2010).

O que o algoritmo faz é filtrar a imagem utilizando um filtro gaussiano e calcular a magnitude do gradiente e os ângulos dos pontos utilizando as derivadas.

Em seguida suprime os pontos de não máxima na magnitude e usa a dupla limiarização e análise de conectividade para detectar e/ou eliminar as bordas.

Por dupla limiarização entende-se um processo durante o algoritmo no qual são geradas 2 imagens, cada uma com um valor de limiar. Por supressão entende-se a eliminação de pontos cuja derivada não é tão alta quanto a de seus vizinhos (GONZALEZ; WOODS, 2010).

Um exemplo do resultado do algoritmo é exibido na Figura 20, ressalta-se que essa resposta é utilizando um grupo de parâmetros bons para a imagem em questão.




Figura 20 – Detecção de borda do Algoritmo Canny
Fonte: adaptado de Bovik (2009)

2.5.5 Watershed

Proposto por Lantuejoul e Beucher (1979), baseia-se em crescimento de regiões inspirados em técnicas de geografia. A palavra *Watershed* designa uma faixa de terra que divide dois rios. Esta técnica propõe a interpretação da imagem de uma maneira diferente e criativa: os valores das intensidades se transformam em altitudes, deste modo a imagem transforma-se em um relevo podendo conter depressões e picos. Seu funcionamento se dá sobre essa imagem transformada. É necessário

imaginar que está caindo água sobre esse relevo sendo identificados três comportamentos para os pontos:

1. Depressões onde a água cai e fica lá;
2. Intermediários onde ao cair ali, provavelmente a água escorrerá para um ponto do tipo 1;
3. Onde a água pode escorrer para mais de um ponto do tipo 1.

O objetivo do algoritmo é encontrar os pontos do tipo 3, os quais identificarão os limites de uma região, por consequência, as bordas de um objeto. O modo, implementação ou lógica, podem variar desde dilatações sucessivas dos pontos de mínima do relevo até acontecer de dois conjuntos que eram desconexos se encontrarem até métodos que envolvem mais passos, como utilizar do gradiente, pontos de mínima local e marcadores de background; até algumas lógicas mais complexas.

Alguns trabalhos que podem ser vistos sobre esse tema podem ser encontrados em Meyer (1991), Meyer e Beucher (1993), Couprie e Bertrand (1997), e em Cousty et al. (2009).

2.6 TRABALHOS RELACIONADOS

Existem diversas pesquisas na área de segmentação de imagem aplicadas em medicina, como, por exemplo, para identificação de câncer ou tumor. Apesar disso, como é de conhecimento geral, no âmbito de processamento de imagens, uma operação usada para obter um bom resultado em um tipo de imagem não necessariamente levará todos os tipos para uma resposta igualmente desejável, pois pode haver uma quantidade maior de ruído, diferenças na nitidez, ou mesmo propriedades intrínsecas da imagem, entre outras razões.

Uma pesquisa com o mesmo foco que esta foi realizada por Cruz (2014) no qual foi feito um estudo comparativo de técnicas de processamento de imagens em Imagens da Mucosa Intestinal. As imagens utilizadas por Cruz (2014) são as mesmas que são utilizadas nesse trabalho, mas o método difere, a saber, no dele é utilizada a imagem completa, enquanto no presente trabalho é utilizada uma parcela apenas, parcela está livre de ruído. O algoritmo mais avançado que ele utilizou nos testes foi

o Canny e limitou-se a utilizar o filtro da mediana, seus resultados não foram satisfatórios, porém servem de base para uma comparação futura.

Um outro trabalho com propósito semelhante foi desenvolvido por Santos (2002) com aplicação sobre detecção de nódulos em mamas duras. Neste trabalho o autor utilizou o algoritmo de Watershed e obteve 93% de acertos na identificação de nódulos em mamas densas. Neste trabalho é utilizado pré-processamento e pós-processamento.

Ao deparar-se com imagens de pouco contraste, Santos (2002) utilizou equalização do histograma para solucionar o problema, caso seja necessário eliminar algum ruído após a segmentação é utilizado rotulação, uma técnica baseada em vizinhança para classificar pixels em zero ou um, ou seja, é utilizado para imagens binárias.

Utilizando as mesmas imagens do presente trabalho Silveira et al. (2014) conseguiram melhorar a segmentação utilizando principalmente de três técnicas, a saber: Expansão de Contraste e operações de Morfologia Matemática como forma de pré-processamento e o Watershed para segmentação. Porém, o resultado obtido através dos experimentos ainda não foi capaz de segmentar completamente as imagens.

3 EXPERIMENTAÇÃO

No presente capítulo são apresentadas as etapas de desenvolvimento do trabalho. Dessa maneira, a Seção 3.1 descreve sobre o processo de aquisição das imagens, a Seção 3.2 sobre as ferramentas que são utilizadas, e, por fim, a Seção 3.3 discorre a metodologia para a realização do trabalho.

3.1 AQUISIÇÃO DAS IMAGENS

As imagens utilizadas no presente trabalho foram obtidas através de exames de endoscopia realizados na clínica PRIMED (PRIMED, 2013) pelo Dr. Fábio Quirilo Milléo. Após serem tiradas, as imagens são então magnificadas 100 vezes e disponibilizadas após terem sido aprovadas por um comitê de ética.

Nesta fase não há intervenção de nenhum profissional da área de computação, é toda feita pelo médico em questão. Por questões intrínsecas à aplicação, a imagem sempre terá um ruído, o flash.

3.2 FERRAMENTAS

Como o material utilizado é composto de imagens, então faz-se necessário encontrar algumas bibliotecas com operações básicas já implementadas. As possibilidades iniciais eram duas: uma em C – OpenCV, uma biblioteca código aberto – e uma em Java, JAI, a qual também é código aberto e providencia interfaces para manipulação de imagens. Foi escolhido trabalhar com a linguagem C pois há mais afinidade com a linguagem. Após um período de adaptação e uma pesquisa maior na área, foi então decidido que a pesquisa seria realizada utilizando a ferramenta Matlab®, a qual possui a maioria dos algoritmos de segmentação já implementados e dispõem de uma vasta bibliografia online.

3.3 METODOLOGIA

O presente trabalho testa aplicações de transformações de imagem e segmentação. Para tal, a metodologia utilizada para o desenvolvimento é a

experimental, por consequência das técnicas aceitarem uma grande quantidade de valores, por exemplo: alguns algoritmos de segmentação aceitam variações de até nove casas decimais em um de seus parâmetros.

Para a aplicação das técnicas utilizou-se 3 abordagens. A primeira, ilustrada na Figura 21 consiste em aplicar apenas a segmentação sobre as imagens. Para isso, utilizou-se os algoritmos: Morfologia Matemática (MM), Marr-Hildreth, Canny e Watershed.

Na aplicação destes algoritmos os parâmetros necessários foram variados, para a MM variou-se o elemento estruturante e suas dimensões, para o Marr-Hildreth variou-se o limiar e seu desvio padrão σ . O algoritmo de Canny teve os parâmetros limiar inferior (L), limiar superior (H) e desvio padrão σ variados. No caso do algoritmo de Watershed variou-se o tipo de entrada, podendo ser apenas uma imagem ou três.



Figura 21 – Primeira abordagem
Fonte: Autoria Própria

A segunda abordagem consiste em adicionar a etapa de pré-processamento antes da segmentação, conforme ilustra a Figura 22. Assim, as técnicas de Histograma, Mediana, Expansão de Contraste, Transformada Logarítmica e Filtro Laplaciano são utilizadas, tendo seu coeficiente – Expansão de Contraste e Transformada Logarítmica – ou tamanho – Filtro Laplaciano – variados. No caso da Mediana utilizar-se-á unicamente a vizinhança-8.

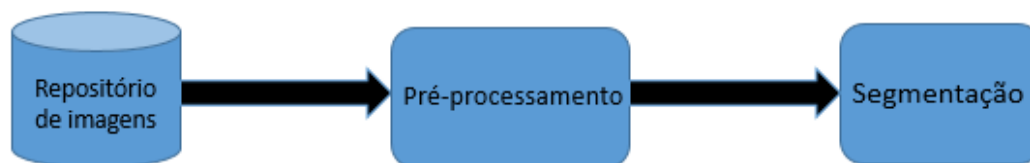


Figura 22 – Segunda abordagem
Fonte: Autoria Própria

A terceira abordagem utiliza a etapa de pós-processamento após a etapa de segmentação, sendo todas as etapas da terceira abordagem ilustradas através da Figura 23.



Figura 23 – Terceira abordagem
Fonte: Autoria Própria

Nesta etapa são utilizadas as técnicas de dilatação e erosão, para as quais foi variado o elemento estruturante utilizado, variado tanto sua forma quanto seu tamanho.

4 RESULTADOS

Neste tópico serão apresentados os resultados obtidos através de cada uma das abordagens apresentadas na metodologia, iniciando-se pelos resultados apresentados quando utilizando-se apenas de segmentação, em seguida utilizando pré-processamento, e, por fim, utilizando também pós-processamento. A imagem que será utilizada como base para os testes é apresentada na letra (A) da Figura 24, como a maioria das técnicas exige que a imagem esteja em tom de cinza para servir de entrada, então na letra (B) apresenta-se a mesma em 256 tons de cinza.




Figura 24 – (A) Recorte de uma parte da Figura 1. (B) Mesmo recorte em 256 tons de cinza.
Fonte: adaptado de PRIMED (2013).

4.1 PRIMEIRA ABORDAGEM

Neste subtópico serão apresentados os resultados quando utilizando apenas os algoritmos de segmentação variando seus parâmetros, a ordem dos testes serão: MM, Marr-Hildreth, Canny, Watershed.

Morfologia Matemática: Os melhores resultados não diferem muito quando utilizado um elemento estruturante ou outro. Por consequência disto serão apresentados aqui os resultados utilizando disco e uma matriz quadrada como ES.

O ES disco possui dois parâmetros, o raio R e um valor N de correção para que o disco se torne quadrado, por *default* o valor é igual a 4, que permite uma aproximação boa o suficiente do formato de disco. Nos testes o valor de N foi mantido fixo em 4. Os resultados são apresentados na Figura 25, é possível notar que as bordas vão se tornando nítidas conforme eleva-se o raio, porém os resultados não melhoram acima disso.




Figura 25 – Utilizando raio igual a: (A) 1 (B) 2 (C) 3 (D) 4.
Fonte: Autoria Própria.

Outro elemento estruturante testado foi a matriz quadrada, os resultados quando usando dimensões pequenas – por exemplo 3x3, 4x4 – não difere muito dos apresentados anteriormente. Assim como nos outros ES, ao usar dimensões maiores a imagem fica “borrada”, conforme é possível notar nas letras (C) e (D) da Figura 26.




Figura 26 – Utilizando matriz de dimensão igual a: (A)3x3 (B)4x4 (C)8x8 (D)10x10.
Fonte: Autoria Própria.

É possível concluir que a segmentação através de Morfologia Matemática é capaz de identificar apenas uns indícios das bordas dos vilos, não conseguindo segmentar completamente nenhum dos elementos presentes na imagem.

Marr-Hildreth: Para este algoritmo são utilizados 2 parâmetros: limiar e σ , primeiramente variando o valor do limiar e mantendo o valor de σ fixo em seu *default*. Vale ressaltar que o limiar tem uma sensibilidade maior do que 9 casas decimais. Conforme a Figura 27 é possível notar que o algoritmo não segmenta bem variando apenas o limiar, ocorrendo o erro de ele encontrar bordas onde não existem.

É válido ressaltar que o resultado conter mais bordas do que realmente existem na imagem original não é um resultado necessariamente agradável, pois não aconteceu dos resultados serem o desejado e um adicional de indesejados.




Figura 27 – $\sigma = 2$, valores de limiar: (A)0,0 (B)0,002 (C)0,0035 (D)0,005.
Fonte: Autoria Própria.

Alterando o valor da variável responsável pelo desvio padrão na parte que define as arestas, o σ , o resultado do algoritmo varia significativamente. O valor desta variável é por *default* igual a 2, ao diminuí-lo o número de arestas aumenta, ao aumenta-lo o número de arestas encontradas diminui. Na Figura 28 o valor do limiar foi mantido fixo em 0,002 – a letra (B) da Figura 27 – e seu σ variado para (A) 1; (B) 1,5; (C) 2,25 e (D) 3. Os resultados da aplicação do algoritmo de Marr-Hildreth não são significativos fazendo combinações de diferentes limiares e diferentes σ .




Figura 28 – limiar = 0,002, σ = (A)1 (B)1,5 (C)2,25 (D)3.
Fonte: Autoria Própria.

Canny: O algoritmo de Canny possui os mesmos parâmetros que o algoritmo de Marr-Hildreth, a diferença é que o de Canny possui 2 limiares – um para bordas fortes e outro para bordas fracas. Sendo assim ele possui os parâmetros: L , H e σ para os limiares inferior, superior e para o desvio padrão, respectivamente.

Apesar de não ter sido capaz de identificar os vilos, este algoritmo possui resultados mais significativos do que os anteriores. Na Figura 29, em (A) vê-se que aparecem os contornos dos vilos, utilizando os parâmetros com valores $L = 0,05$, $H = 0,3$ e $\sigma = \sqrt{2}$, nas seguintes, (B), (C) e (D) o valor de L e H foi mantido fixo e σ variado para 3, 4 e 6, respectivamente.




Figura 29 - $L = 0,05$; $H = 0,3$; (A) $\sigma = \sqrt{2}$ (B) $\sigma = 4$ (C) $\sigma = 5$ (D) $\sigma = 6$
Fonte: Autoria Própria.

Watershed: O Matlab possui duas implementações do Watershed, uma delas recebendo apenas a foto como entrada, e outra recebendo um conjunto maior de parâmetros. Nesta primeira etapa será apresentado o resultado com a entrada sendo constituída apenas de uma imagem.

A resposta deste algoritmo difere um pouco das anteriores, pois cada objeto que ele encontra na imagem será pintado de uma cor, cada cor é uma bacia dentro da imagem. O tipo de resultado foi semelhante ao do Marr-Hildreth, conforme presente na Figura 30.




Figura 30 – aplicação do Watershed.
Fonte: Autoria Própria.


Considerações Parciais: Neste primeiro grupo de testes todos os algoritmos, excetuando o Canny, apresentaram resultados altamente insatisfatórios, segmentando pouco ou supersegmentando, ou seja, segmentando mais do que deveria.

O algoritmo de Canny, por outro lado, foi capaz de detectar o contorno de alguns vilos, porém não foi capaz de fechá-los.

4.2 SEGUNDA ABORDAGEM

Nesta seção são apresentados os resultados dos algoritmos de segmentação quando a entrada foi pré-processada pelas técnicas: Histograma, Mediana, Expansão de Contraste, Transformada Logarítmica e Filtro Laplaciano.

Histograma: Utilizando a Equalização de Histograma a imagem sofre uma mudança visível, o que resulta em uma mudança na resposta da maioria dos algoritmos de segmentação. A Figura 31 apresenta o histograma da imagem padrão em tons de cinza. Em seguida, a Figura 32 apresenta o histograma equalizado e a imagem resultante é apresentada na Figura 33.



**Figura 31 – Histograma da imagem padrão em tons de cinza.
Fonte: Autoria Própria.**




Figura 32 – Histograma equalizado da imagem padrão em tons de cinza.
Fonte: Autoria Própria.



Figura 33 – Imagem resultante do histograma equalizado.
Fonte: Autoria Própria.

Utilizando a Figura 33 como entrada para os algoritmos a resposta de todos – excetuando o Watershed – mudou para melhor. Os resultados são apresentados na Figura 34.


A letra (A) da Figura 34 é a resposta do algoritmo de Canny utilizando o conjunto de parâmetros $L = 0,05$; $H = 0,3$ e $\sigma = 5$. Nota-se que os vilos próximos ao vilo central foram melhor segmentados, não juntando dois vilos em um só, como era o caso do central e o que está imediatamente à sua direita. Apesar de ter os contornos definidos, a segmentação completa não foi efetuada e nenhum contorno foi fechado completamente.

Na letra (B) está presente a resposta do algoritmo de Marr-Hildreth. Apesar da resposta ser menos significativa que a do Canny ainda há detalhes interessantes sobre a aplicação da Equalização de Histograma: o vilo do meio se destaca um pouco, apesar de não ter os contornos definidos. O conjunto de parâmetros utilizados foi: limiar = 0,017 e $\sigma = 2$.

Presente na letra (C) está o resultado utilizando Morfologia Matemática, o ES utilizado para este teste foi uma matriz quadrada 3x3, este elemento foi escolhido por apresentar bons resultados.

O resultado da aplicação desta técnica foi a que mais mudou em comparação com os resultados da primeira abordagem, anteriormente só havia a identificação de alguns traços, sendo difícil de até mesmo evocar a imagem original através do resultado, diferentemente do que está presente na letra (C). Porém, apesar de ser possível ver os vilos na imagem, eles não estão com os contornos definidos e possuem muitas informações além das bordas.


O resultado da aplicação do algoritmo de Watershed está presente na letra (D), igualmente o resultado da abordagem anterior, a aplicação da Equalização de Histograma não melhorou o resultado final. O resultado final não difere significativamente caso se use apenas a imagem como entrada ou se usando um conjunto maior de parâmetros, sendo assim, optou-se por mostrar o resultado da operação com apenas um parâmetro.




(A)



(B)



(C)



(D)

Figura 34 – Resultado da aplicação do algoritmo de (A) Canny (B) Marr-Hildreth (C) Morfologia Matemática (D) Watershed sobre a Figura 33.

Fonte: Autoria Própria.

Mediana: Ao aplicar esta técnica à imagem padrão em tons de cinza a imagem resultante não aparenta – ao olho humano – ter mudado, mas os resultados dos algoritmos de segmentação diferem dos da primeira abordagem.

A mediana é utilizada para suavizar a imagem, com a finalidade de diminuir os ruídos e deixar a imagem mais “homogênea”, diminuindo a chance de supersegmentar, sendo assim, ela altera mais os resultados de algoritmos que estão com este problema.

Como a MM não havia resultado em uma imagem com muita informação, a aplicação da mediana tornou o resultado ainda mais fraco, conforme é possível ver na letra (B) da Figura 35, a letra (A) é o resultado da primeira abordagem. Para este teste foi utilizado uma matriz 3x3 como ES.




Figura 35 – (A) Resultado da primeira abordagem (B) imagem resultante utilizando mediana como pré-processamento.
Fonte: Autoria Própria.

O algoritmo de Marr-Hildreth também teve um resultado mais “limpo”, caso fosse o caso de haver segmentado corretamente e mais uns traços adicionais, a mediana seria uma boa ferramenta para limpar esses traços. Na Figura 36 utilizou-se

os parâmetros $\text{limiar} = 0,002$ e $\sigma = 2$, na letra: (A) resultado sem mediana, (B) com mediana.




Figura 36 – $\text{limiar} = 0,002$ e $\sigma = 2$, (A) sem mediana, (B) com mediana.
Fonte: Autoria Própria.

O algoritmo de Canny, menos sensível a ruídos, tem uma mudança menor na aplicação da mediana, mas a mudança é do mesmo tipo: uma resposta mais “limpa”. Os parâmetros utilizados na Figura 37 são: $L = 0,05$; $H = 0,3$; $\sigma = 4$; à esquerda, na letra (A), não foi utilizada a mediana, à direita, sim.

Sendo o Watershed o algoritmo que mais supersegmentou, a aplicação da mediana alterou visivelmente o resultado. Anteriormente, como presente em (A) da Figura 38, há muitos pequenos pontos de diversas cores, esses pontos ficam maiores em (B), na qual foi aplicada a mediana. Em (C) foi utilizada a outra abordagem do Watershed, no qual são utilizadas 2 outras imagens auxiliares, formando assim um conjunto de 3 imagens, as 3 são a mesma: a resultante da mediana. Nota-se que a supersegmentação diminuiu ainda mais.




Figura 37 – $L = 0,05$; $H = 0,3$; $\sigma = 4$; (A) sem mediana, (B) com mediana.
Fonte: Autoria Própria.





Figura 38 – (A) sem mediana, (B) com mediana sem auxiliares (C) com mediana e auxiliares.
Fonte: Autoria Própria.

Expansão de Contraste: Esta técnica aumenta a diferença entre a tonalidade dos pixels, quanto maior o coeficiente usado, maior a diferença. A aplicação utilizando

coeficientes superiores a 10 altera a imagem suficientemente para ser notada pelo olho humano e ao utilizar 100 como coeficiente a imagem fica muito próxima da binarização – onde os valores da imagem ou são 0 ou são 1. A variação da imagem conforme eleva-se o coeficiente é apresentada na Figura 39.



**Figura 39 – (A) Imagem original (B) coeficiente = 25 (C) coeficiente = 50 (D) coeficiente = 100.
Fonte: Autoria Própria.**

Assim como na Equalização de Histograma, as alterações influenciam bastante a segmentação, para exemplificar, primeiro será mostrado o resultado do algoritmo de Canny sobre a letra (B), (C) e (D) da Figura 39.

Os resultados estão presentes na Figura 40, onde os parâmetros do Canny foram mantidos constantes em $L = 0,05$; $H = 0,3$; $\sigma = 4$ e a imagem de entrada variada com coeficiente tendo valor igual a: (B) 25, (C) 50, (D) 100.

Nota-se que o número de informações – bordas encontradas – aumentou juntamente com o coeficiente, havendo um ponto positivo e outro negativo.

O ponto positivo é que foi encontrado um número maior de contornos dos vilos, contudo, algumas partes da borda real do vilão foram perdidas durante o aumento de contraste, fazendo com que a região de interesse se torne menor que a verdadeira.




Figura 40 – $L = 0,05$; $H = 0,3$; $\sigma = 4$; (A) sem pré-processamento (B) coeficiente = 25 (C) coeficiente = 50 (D) coeficiente = 100.

Fonte: Autoria Própria.

A Figura 41 apresenta os resultados da aplicação dos algoritmos de segmentação. A imagem utilizada foi a contrastada com coeficiente igual a 50. Em (A) a resposta de Canny, com os parâmetros: $L = 0,05$; $H = 0,3$ e $\sigma = 4$. Em (B) a resposta do Marr-Hildreth com parâmetros: limiar = 0,002 e $\sigma = 2$. Presente em (C) está a MM utilizando como ES uma matriz quadrada 3x3. Em (D) o resultado do Watershed.

O algoritmo de Marr-Hildreth apresenta uma resposta mais agradável que o da primeira etapa, apresentando o contorno de alguns vilos, porém permanece tendo uma resposta inferior a do Canny.




Figura 41 – Resultado do (A) Canny, parâmetros: $L = 0,05$; $H = 0,3$ e $\sigma = 4$. (B) Marr-Hildreth, parâmetros: limiar = 0,002 e $\sigma = 2$. (C) MM, como ES uma matriz 3x3. (D) Watershed. Imagem pré-processada usando aumento de contraste com coeficiente = 50.

Fonte: Autoria Própria.

A MM apresenta uma resposta semelhante à da Equalização de Histograma, apresentando o “conteúdo” dos vilos, mas não suas bordas.

A maior mudança foi no algoritmo de Watershed – utilizado na forma dos 3 parâmetros, sendo as 3 a mesma imagem –, que apesar de supersegmentar definiu toda uma região como sendo o mesmo objeto, isolando o vilão central e o que fica logo à sua direita.

Transformada Logarítmica: Esta técnica também necessita de um coeficiente, conforme eleva-se o coeficiente mais clara torna-se a imagem. Conforme presente na Figura 42, os resultados são apresentados de acordo com a variação do coeficiente: em (A) o coeficiente vale 1; em (B) 1,5; (C) 2; (D) 2.5.




Figura 42 – Transformada Logarítmica com coeficiente (A) 1 (B) 1.5. (C) 2 (D) 2.5.
Fonte: Autoria Própria.

A aplicação da segmentação sobre as imagens resultantes desta técnica gerou resultados iguais ou piores aos da primeira abordagem. Por questão de espaço os resultados foram então omitidos.

Filtro Laplaciano: Foram aplicados os dois filtros mostrados na Figura 15, o resultado de ambos é exibido na Figura 43. A imagem resultante do filtro 3x3 é apresentada em (A) e em (B) está a resultante do filtro 5x5. A imagem com as bordas aguçadas é apresentada na letra (C).

Ao utilizá-la como entrada para os algoritmos de segmentação o único algoritmo que teve um destaque positivo foi o de Canny, que foi capaz de identificar quase completamente um vilo logo à direita do central.




Figura 43 – (A) Resultante da aplicação do Filtro Laplaciano 3x3 da Figura 15 (B) Aplicação do Filtro Laplaciano 5x5 da Figura 15 (C) Imagem com as bordas aguçadas. Fonte: Autoria Própria.

A resposta dos algoritmos é mostrada na Figura 44. Em (A) o algoritmo de Canny com os parâmetros: $L = 0,05$; $H = 0,3$ e $\sigma = 4$. Em (B) Marr-Hildreth, parâmetros: limiar = 0,002 e $\sigma = 2$. (C) Morfologia Matemática utilizando como elemento estruturante uma matriz 3x3. (D) Watershed utilizando 3 imagens, as 3 sendo a mesma.




Figura 44 – Imagem pré-processada com Filtro Laplaciano, resultado do algoritmo (A) Canny parâmetros: $L = 0,05$; $H = 0,3$ e $\sigma = 4$. (B) Marr-Hildreth: limiar = 0,002 e $\sigma = 2$. (C) Morfologia Matemática, elemento estruturante uma matriz 3x3. (D) Watershed.
Fonte: Autoria Própria.

Considerações Parciais: Dentre as combinações de técnicas utilizadas, em geral, a combinação das técnicas selecionadas para pré-processamento com o Watershed e com MM não geraram resultados satisfatórios.

O algoritmo de Marr-Hildreth aliado ao pré-processamento, em alguns casos, obteve uma melhora significativa. Porém, a mesma técnica de pré-processamento aliada ao algoritmo de Canny obteve uma resposta ainda mais significativa. Por isso, a seguir apresenta-se apenas as modificações no resultado do algoritmo de Canny.

(A) Histograma e Canny: Esta combinação favoreceu a segmentação de alguns vilos da seguinte forma: melhorando o contorno dos que já haviam sido um pouco identificados e ajudando a identificar novos vilos. Foram destacadas na Figura 45 as principais mudanças em relação à aplicação da Equalização de Histograma. Em (A) a imagem original, em (B) a aplicação do algoritmo de Canny sem pré-processamento e com parâmetros $L = 0,05$; $H = 0,3$; $\sigma = 4$, em (C) sendo pré-processada pela Equalização de Histograma e com parâmetros: $L = 0,05$; $H = 0,3$; $\sigma = 5$.

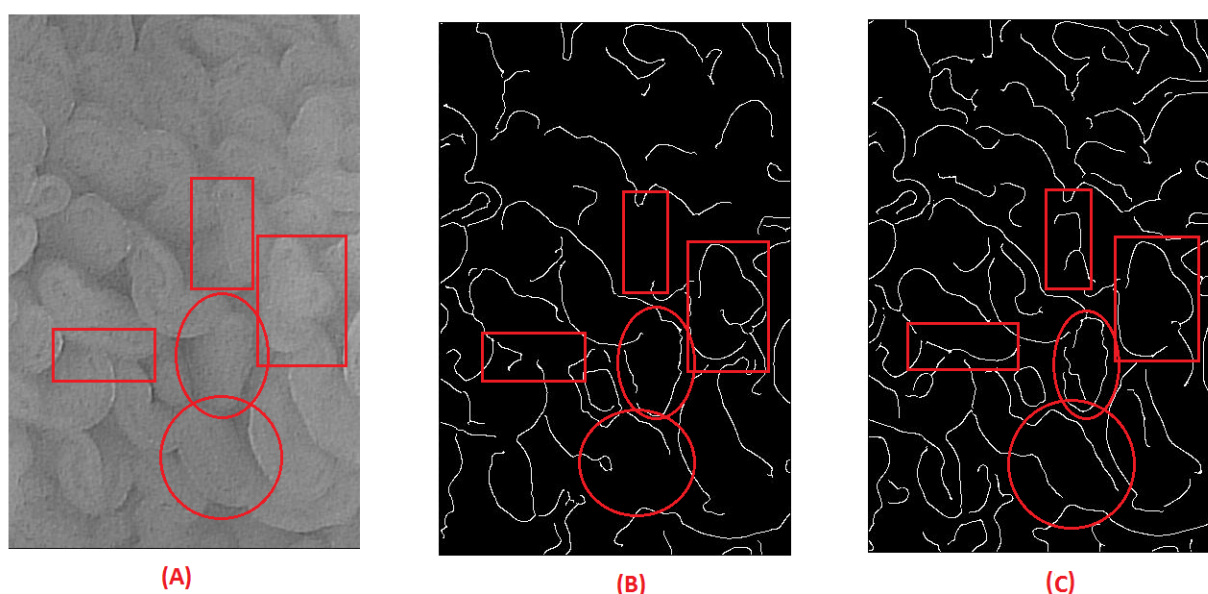


Figura 45 – Em destaque as áreas de interesse (A) Imagem original em 256 tons de cinza. (B) Resposta do algoritmo de Canny sem pré-processamento. (C) Resposta de Canny com aplicação da Equalização de Histograma.

Fonte: Autoria Própria.

(B) Mediana e Canny: A aplicação da mediana removeu alguns traços na segmentação, deixando a imagem resultante com menos arestas, porém, das removidas nenhuma alterou significativamente o resultado, por isso a comparação das imagens será omitida.

(C) Expansão de Contraste e Canny: Esta combinação foi a que mais fez aparecer novos vilos ao preço de eles se “deformarem” um pouco, ou seja, a imagem ficou alterada de modo a perder alguns detalhes como a real área do vilo, mas ganhou em ter o restante da área melhor segmentada.

Na Figura 46 as regiões destacadas por retângulos são algumas das áreas de ganho na segmentação quando aplicado o aumento de contraste, as regiões destacadas por círculos apontam que a área real foi afetada pela aplicação da técnica. Em (A) está presente a imagem original em 256 tons de cinza, em (B) a segmentação

do Canny sem pré-processamento, em (C) a segmentação tendo como pré-processamento o aumento de contraste usando um coeficiente de valor igual a 50. Tanto em (B) quanto em (C) os parâmetros do Canny foram: $L = 0,05$; $H = 0,3$; $\sigma = 4$.

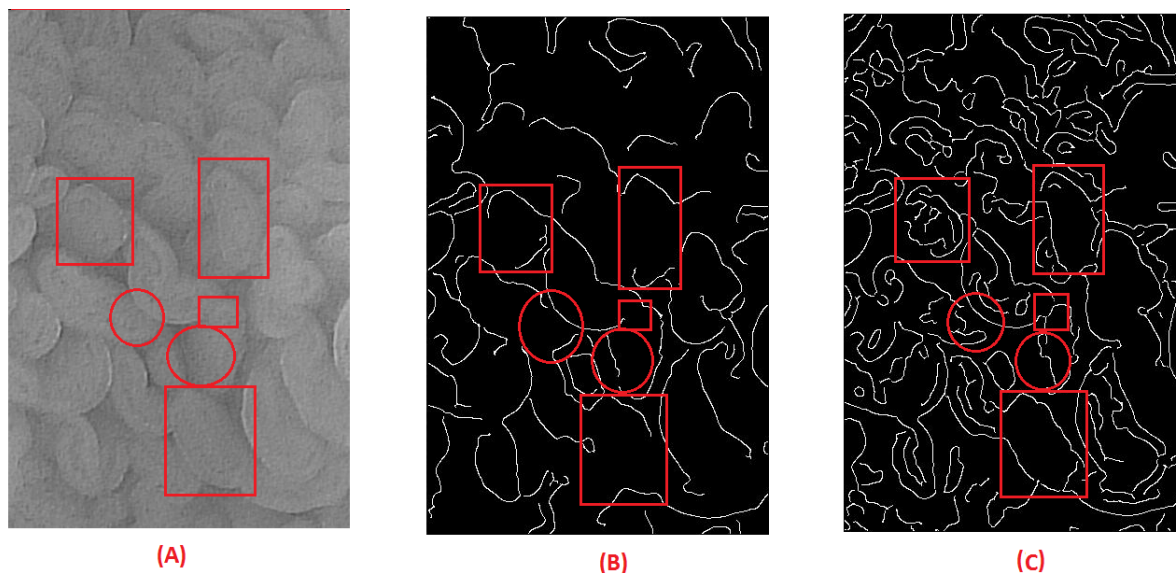


Figura 46 – Em destaque as áreas de interesse (A) Imagem original em 256 tons de cinza. (B) Resposta do algoritmo de Canny sem pré-processamento. (C) Resposta de Canny com aplicação do aumento de contraste.

Fonte: Autoria Própria.

(D) Transformada Logarítmica e Canny: Esta combinação não gerou resultados melhores, portanto sua comparação será suprimida.

(E) Filtro Laplaciano e Canny: Esta combinação gerou resultados mais modestos, havendo melhoras em algumas partes e piores em outras. A Figura 47 apresenta as mudanças ocorridas.

A principal melhora é destacada com um retângulo, enquanto algumas piores decorrentes da aplicação deste pré-processamento são destacadas através de um círculo. Em (A) está presente a imagem original em tons de cinza, em (B) a segmentação através do algoritmo de Canny sem pré-processamento e em (C) a segmentação utilizando o mesmo algoritmo tendo o Filtro Laplaciano como pré-processamento. Tanto em (B) quanto em (C) o algoritmo de Canny teve como parâmetro: $L = 0,05$; $H = 0,3$; $\sigma = 4$.




Figura 47 – Em destaque as áreas de interesse (A) Imagem original em 256 tons de cinza. (B) Resposta do algoritmo de Canny sem pré-processamento. (C) Resposta de Canny com aplicação do Filtro Laplaciano.

Fonte: Autoria Própria.

4.3 TERCEIRA ABORDAGEM

Como pós-processamento será utilizado as operações de erosão e dilatação de Morfologia Matemática, por padrão o elemento estruturante utilizado será uma matriz quadrada 3x3. Por questões de espaço só serão apresentados o resultado final incluindo pós-processamento das combinações: histograma e segmentação, Expansão de Contraste e segmentação, e Filtro Laplaciano e segmentação.

Dilatação: Operação que tem por característica “engordar” a imagem, no caso da aplicação em imagens binárias as linhas brancas se tornam mais grossas, servindo para conectar linhas que estavam próximas, mas não foram conectadas.

Na Figura 48 apresenta-se o resultado ao aplicar dilatação sobre a segmentação utilizando MM sendo pré-processada por: (A) Expansão de Contraste com coeficiente igual a 50, (B) Equalização de Histograma e (C) Filtro Laplaciano.

Na Figura 49 apresenta-se a dilatação sobre o algoritmo de Marr-Hildreth, sendo pré-processado por (A) Expansão de Contraste com coeficiente = 50, segmentação com parâmetros: limiar = 0,002 e $\sigma = 2,4$; (B) Equalização de Histograma, segmentação com parâmetros: limiar = 0,017 e $\sigma = 2$; (C) Filtro Laplaciano, com parâmetros: limiar = 0,002 e $\sigma = 2$.




Figura 48 – Resultado da dilatação aplicada à segmentação através de MM sendo pré-processada por (A) Expansão de Contraste. (B) Equalização de Histograma. (C) Filtro Laplaciano.

Fonte: Autoria Própria.




Figura 49 – Resultado da dilatação aplicada à segmentação através de Marr-Hildreth sendo pré-processado por (A) Expansão de Contraste. (B) Equalização de Histograma. (C) Filtro Laplaciano.

Fonte: Autoria Própria.

Presente na Figura 50 estão os resultados da aplicação da dilatação sobre o algoritmo de Canny. É possível notar que alguns vilos quase se fecharam completamente, caso utilize-se um ES maior então eles se fecharão em decorrência da linha se tornar ainda mais grossa.

Os parâmetros L e H foram mantidos constantes nas 3 segmentações, a saber, com os valores 0,05 e 0,3, respectivamente. Quanto ao pré-processamento: (A) a imagem foi pré-processada pela Equalização de Histograma e o σ do Canny teve o

valor igual a 5; (B) pré-processada pelo aumento de contraste com coeficiente igual a 50, $\sigma = 4$; (C) pelo Filtro Laplaciano, $\sigma = 4$.




Figura 50 – Resultado da dilatação aplicada à segmentação do algoritmo de Canny sendo pré-processado por (A) Equalização de Histograma. (B) Expansão de Contraste. (C) Filtro Laplaciano.

Fonte: Autoria Própria.

Exibido na Figura 51 estão os resultados da aplicação da dilatação aos resultados da segunda abordagem envolvendo o Watershed. Ao aplicar essa técnica, as linhas de Watershed – as linhas brancas da imagem – é que são dilatadas, ocupando um espaço maior.

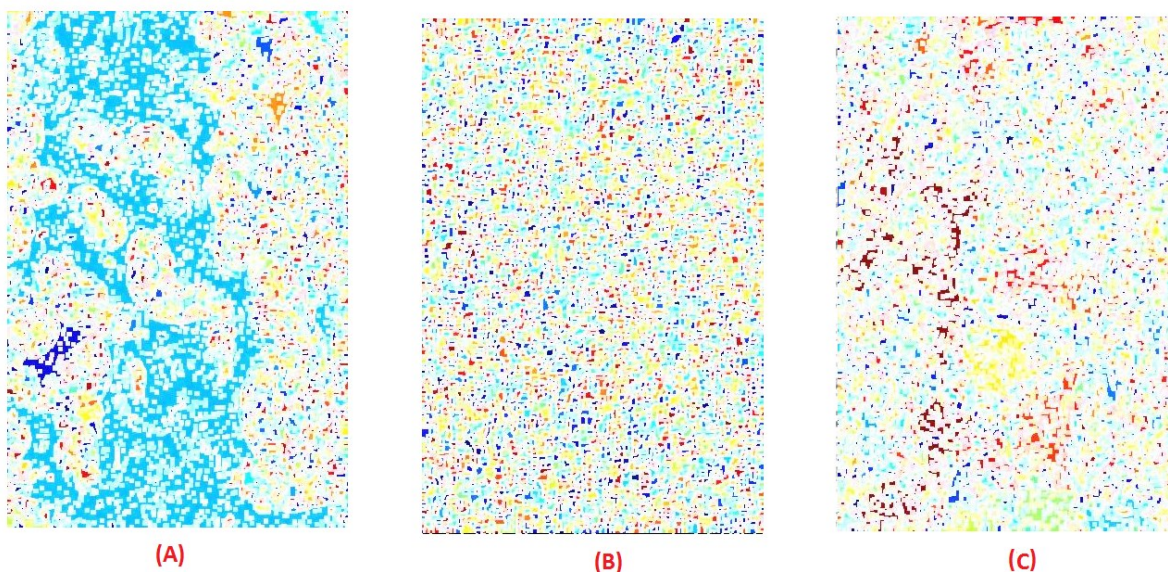


Figura 51 – Resultado da dilatação aplicada à segmentação através de Marr-Hildreth sendo pré-processado por (A) Expansão de Contraste. (B) Equalização de Histograma. (C) Filtro Laplaciano.

Fonte: Autoria Própria.

Em (A) a imagem foi pré-processada pelo aumento de contraste com coeficiente igual a 50. Em (B) pela Equalização de Histograma, ao passo que em (C) pelo Filtro Laplaciano.

Erosão: Ao aplicar a erosão como pós-processamento as imagens resultaram em imagens sem nada, exceto o Watershed, o qual mantém as cores, mas as linhas de Watershed são eliminadas. Como forma de exemplo apresenta-se na Figura 52 na letra (A) uma segmentação pré-processada do Watershed e em (B) essa mesma segmentação pós-processada por uma erosão.




Figura 52 – Watershed (A) sem erosão (B) com erosão.
Fonte: Autoria Própria.

Considerações Parciais: A erosão aplicada sozinha como pós-processamento não gerou bons resultados. A dilatação, por outro lado, mostrou-se útil para estender contornos de modo a fechar os contornos dos vilos.

A Figura 53 exhibe as mudanças ocorridas no resultado final conforme são adicionadas as etapas: em (A) o resultado da segmentação utilizando o algoritmo de Canny sem pré nem pós-processamento, já em (B) a imagem foi previamente pré-processada pelo aumento de contraste, utilizando coeficiente = 50. Por fim, em (C) houve adicionalmente a dilatação por um ES, uma matriz quadrada 7x7. Os

parâmetros do algoritmo de Canny foram mantidos constantes nos 3 casos em $L = 0,05$; $H = 0,3$ e $\sigma = 4$.




Figura 53 – Evolução dos resultados (A) segmentação sem pré nem pós processamento (B) pré-processada (C) pré e pós processada
Fonte: Autoria Própria.

As regiões destacadas em vermelho são algumas das áreas que tiveram ganho durante o processo, seja com a identificação dessa área através de pré-processamento ou com o fechamento dos contornos através do pós-processamento.

A aplicação do mesmo recurso nas outras combinações foi omitida pois o resultado é muito semelhante: fecha pequenos espaços que ficaram abertos.

5 CONCLUSÃO

Este capítulo apresenta as considerações finais do trabalho fazendo uma relação dos resultados obtidos com o objetivo geral e específicos, além de propor trabalhos futuros na mesma linha de desenvolvimento.

O diabetes é uma doença que tem afligido cada vez mais a população do mundo todo e a expectativa é que afete ainda mais no futuro. O seu diagnóstico normalmente é feito através de exame de sangue, muitas vezes realizado quando o paciente já está em estado avançado. Pesquisas na área tem mostrado que existe uma relação entre o diabetes e a hipertrofia da mucosa intestinal, sendo esta identificada antes do aparecimento do diabetes.

Dessa forma, a identificação de um padrão da mucosa intestinal, obtida por meio de imagens, pode contribuir com o diagnóstico precoce da doença. Assim, a análise dessas imagens é de grande importância para se obter uma maior compreensão das características das imagens da mucosa intestinal assim como das dificuldades inerentes às imagens.

Este trabalho apresentou um estudo de técnicas de segmentação de imagens da mucosa intestinal. Para isto, fez-se uso de três abordagens para o processamento dessas imagens.

A primeira abordagem permitiu a validação de que os algoritmos de segmentação selecionados não são capazes de gerar resultados agradáveis, sendo necessário o pré-processamento, gerando assim a segunda abordagem. O algoritmo que mais se destacou na primeira etapa foi o de Canny.

Utilizando-se das técnicas de pré-processamento averiguou-se o baixo contraste e que técnicas que trabalham com essa característica modificam consideravelmente o resultado, como é o caso das técnicas: Equalização de Histograma e aumento de contraste. Além destas, a técnica Filtro Laplaciano também contribuiu positivamente para a segmentação.

Das combinações das técnicas selecionadas de pré-processamento com as de segmentação – segunda abordagem – as que envolveram Equalização de Histograma, Expansão de Contraste, Filtro Laplaciano e Canny foram as que mais se destacaram por haver mais vilos identificados e com melhor qualidade, sendo estes resultados então utilizados na terceira abordagem.

Uma das técnicas – erosão – de pós-processamento não foi útil ao resultado final, pois ela elimina as linhas resultantes da segmentação. A outra, a saber, a dilatação, se mostrou uma ferramenta valiosa para corrigir partes da segmentação que não se fecharam, fazendo com que o melhor resultado do trabalho esteja presente nesta terceira e última abordagem.

Embora a aplicação dessas técnicas tenha apresentado um resultado mais significativo, ainda não é o suficiente para a identificação de um padrão da mucosa intestinal pois é necessário que o resultado final da segmentação contenha a borda de todos ou quase todos os vilos.

5.1 TRABALHOS FUTUROS

Conforme os resultados obtidos neste trabalho através das técnicas de segmentação, pré-processamento e pós-processamento, é possível dar continuidade à pesquisa abordando outras técnicas visando segmentar melhor as imagens da mucosa intestinal. Dentre as pesquisas futuras pode-se destacar:

- Outras técnicas de pré-processamento que melhorem o contraste da imagem;
- Algoritmos diferentes dos utilizados neste trabalho para segmentação;
- Técnicas diferentes de pós-processamento, como fechamento e abertura;
- Utilizar os canais RGB e transformadas para outros modelos de cores;
- Utilizar outras implementações do algoritmo de Watershed.

REFERÊNCIAS

BOLDRINI et al. **Álgebra linear**. 3.ed. São Paulo: Harper & Row do Brasil, 1980. 411p.

BOVIK, A. **The Essencial Guide to Image Processing**. San Diego: Academic Press, 2009.

CANNY, J. F. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 8, p. 679–698, 1986.

COUPRIE, M.; BERTRAND, G. Watersheds, mosaics, and the emergence paradigm. **Discrete Applied Mathematics**, Vol. 147, p.301-324,1997.

CRUZ, A. F. F. **Estudo Comparativo de Técnicas de Processamento de Imagens em Imagens da Mucosa Intestinal**. 2014.67f. Monografia (Graduação em Bacharelado em Ciência da Computação) – Universidade Tecnológica Federal do Paraná, Paraná.

DOUGHERTY, E.R. **Digital Image Processing Methods**. New York: CRC Press, 1994.

DUNCAN, J; AYACHE, N. Medical Image Analysis: Progress over two decades and the challenges ahead. **IEEE Transactions on Pattern Analysis and Machine Intelligece**, p.85-106, 2000.

FREI, W. CHEN, C. Fast Boundary Detection: A Generalization and a New Algorithm, **I.E.E.E. Transactions on Computers**, Vol C-26. No. 10,1977

GONZALEZ et al. **Digital Image Processing Using MATLAB**. 2nd. ed. New York: Pearson, 2003

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. 3. ed. São Paulo: Pearson, 2010.

International Diabetes Federation . What is Diabetes? Disponível em: <<http://www.idf.org/worlddiabetesday/toolkit/children/what-is-diabetes>>. Acesso em 03 dez. de 2014.

COUSTY et al. Watershed Cuts: Minimum Spanning Forests and the Drop of Water Principle. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. p. 1362-1374,2009.

KAHN, E. The relative contributions of insulin resistance and beta-cell dysfunction to the pathophysiology of Type 2 diabetes. **Diabetologia**, v. 46, p. 3-19, 2003.

KARLSSON et al. Gut metagenome in European women with normal, impaired and diabetic glucose control. **Nature**, v. 498, p. 99–103, 2013.

LANTUEJOU, C.; BEUCHER, S. Use of Watersheds in Contour Detection. **International Workshop on image processing : Real-time Edge and Motion detection/estimation**. 1979.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**, Rio de Janeiro: Brasport, 1999.

MARR, D.; Hildreth, E. Theory of Edge Detection. **Proceedings of the Royal Society of London Series B**, p.187-217, 1980.

MATHERS, J. Nutrient regulation of intestinal proliferation and apoptosis. **Proceedings of the Nutrition Society**. v. 57, p. 219-23, 1998.

MATLAB. **MATLAB The Language of Technical Computing**. Disponível em: <<http://www.mathworks.com/products/matlab/features.html>>. Acesso em 03 dez 2014.

MEYER, F. Un algorithme optimal pour la ligne de partage des eaux. **8^{me} congrès de reconnaissance des formes et intelligence artificielle**, v.02, pages 847–857, 1991.

MEYER, F.; BEUCHER, S. The morphological approach to segmentation: the Watershed transformation. **Mathematical Morphology in Image Processing**, p. 433–481, 1993.

MILLER et al. Proliferation rate and transit time of mucosal cells in small intestine of the diabetic rat. **Gastroenterology**, v. 73, p. 1326-1332, 1977.

PRATT et al. Pseudomedian Filter, **Architectures and Algorithms for Digital Image Processing II**, v. 0534, 1985.

PREWITT, J.M.S. Object Enhancement and Extraction. **Picture Processing and Psychopictoris**, Lipkin, Academic Press, 1970.

PRIMED. **Clínica Primed Medicina Avançada: Serviço de Endoscopia Digestiva**, 2013.

RODRIGUES, M. R. S. **Adaptação digestiva com duodenal switch parcial em pacientes diabéticos e com IMC<35 Kg/m². Análise da resposta clínica, laboratorial e da expressão do gene p53 na mucosa intestinal**. 2012. 132 f. Tese (Doutorado em Fisiopatologia Clínica e Experimental) - Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2012.

SANTOS, V. T. **Segmentação de Imagens Mamográficas para Detecção de Nódulos em Mamas Densas**. 2002.112f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade de São Paulo, São Paulo.

SERRA, Jean. **Image Analysis and Mathematical Morphology**. 1 ed. Academic Press, 1982.

SILVEIRA et al. Image Processing of Intestinal Mucosa. **International Conference on Audio, Language and Image Processing**, p.152-155,2014.

SOBEL, I. Neighborhood coding of binary images for fast contour following and general array binary processing. **Computer Graphics Image Process**, vol. 8, 1978.

VERDAM et al. **Small Intestinal Alterations in Severely Obese Hyperglycemic Subjects**. J Clin Endocrinol Metab. February; v. 96 n. 2, p. 379-383, 2011.

WHO. **Facts sheet on diabetes, obesity and overweight**. Geneva: World Health Organization, 2006.