

CENTRO UNIVERSITÁRIO FEEVALE

LUANA NOGUEROL

SISTEMA DE INFORMAÇÃO COMO APOIO AO DIGNÓSTICO
EM PARASITOLOGIA

Novo Hamburgo, novembro de 2008.

LUANA NOGUEROL

SISTEMA DE INFORMAÇÃO COMO APOIO AO DIAGNÓSTICO
EM PARASITOLOGIA

Centro Universitário Feevale
Instituto de Ciências Exatas e Tecnológicas
Curso de Sistemas de Informação
Trabalho de Conclusão de Curso

Professor Orientador: Marta Rosecler Bez
Professor Co-orientador: Rejane Giacomelli Tavares

Novo Hamburgo, novembro de 2008.

AGRADECIMENTOS

Quero agradecer a Deus por todas as oportunidades e pessoas maravilhosas que foram colocadas no meu caminho, e claro, a essas pessoas, que participam ou participaram da minha vida de alguma forma. Também gostaria de agradecer aos meus pais, que me deram a vida e cuidaram de mim com tanto amor e zelo, me dando força e incentivo para vencer os meus medos e dificuldades. À minha irmã, que encanta os meus dias com o seu sorriso. Aos outros membros de minha família, por me apoiarem. Ao Fabrício, que ficou ao meu lado nesta jornada. Aos meus colegas de faculdade, principalmente Deise, Carla e Pedro, por participarem da minha vida de forma tão especial. À minha orientadora e amiga Marta, que sempre me ajudou com o seu conhecimento e suas palavras animadoras, fazendo este trabalho acontecer. À minha co-orientadora Rejane e à minha colega Andressa, que contribuíram com este trabalho através dos seus conhecimentos em parasitologia.

RESUMO

O objetivo deste trabalho é buscar formas tecnológicas para auxiliar nos diagnósticos parasitológicos. Assim, é projetado um sistema baseado em pesquisas na área de computação gráfica e parasitologia, no qual serão analisadas imagens de amostras de ovos de parasitas encontrados em exames parasitológicos de fezes (EPF). Estão sendo pesquisadas técnicas de processamento de imagem que auxiliem no desenvolvimento de um sistema para diagnosticar ovos de parasitas, baseado na estrutura morfológica dos mesmos. Consequentemente, o presente trabalho pretende contribuir para a informatização da área da saúde, através do uso de imagens de exames médicos, auxiliando na formulação de um diagnóstico mais rápido e com maior precisão.

Palavras-chave: SAD, imagem, parasitologia, diagnóstico, processamento de imagens.

ABSTRACT

The objective of this work is to search technological forms to assist in the parasitological diagnostic. Thus, a system based on research in the computer graphics area and parasitology will be projected, in which images of parasites egg samples will be analyzed of found in parasitological excrement examinations (PEE). They are being searched techniques of image processing that assist in the development of a system to diagnosis parasites eggs, established in the morphologic structure of the same ones. Consequently, the present work intends to contribute for the informatization area of health through the use of medical images, assisting in the formularization of a faster diagnosis and with bigger precision.

Key words : SAD, image, parasitology, diagnostic, Image Processing

LISTA DE FIGURAS

Figura 1.1 - Ovos de nematelmintos mais encontrados.....	15
Figura 1.2 - Cistos de protozoários mais encontrados.....	15
Figura 1.3 - Método de Sedimentação Espontânea	17
Figura 1.4 - Ovo de <i>Trichuris trichiura</i>	18
Figura 1.5 - Ovos de <i>Ascaris lumbricoides</i>	19
Figura 2.1 - Fluxo de atividades do sistema proposto	21
Figura 2.2 - Imagem em escala de cinza e Imagem filtrada com o filtro Gaussiano	26
Figura 2.3 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Sobel sem limiar	28
Figura 2.4 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Prewitt sem limiar.....	29
Figura 2.5 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Roberts sem limiar....	30
Figura 2.6 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Laplace sem limiar....	30
Figura 2.7 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Canny sem limiar.....	31
Figura 2.8 - Imagem filtrada e detectores de bordas	32
Figura 2.9 - Aplicação de <i>floodfill</i> para encontrar as sementes de cada região.....	36
Figura 2.10 - Aplicação de <i>floodfill</i> a partir dos <i>pixels</i> sementes.....	36
Figura 2.11 - Imagem binarizada e imagem aplicada Canny com afinamento	38
Figura 2.12 - Imagem binária e imagem aplicado o algoritmo de detecção de perímetro	39
Figura 3.1 - Demonstração de uma classe e dois objetos.	42
Figura 3.2 - Caso de Uso do processo de análise de amostras fecais	43
Figura 3.3 - Diagrama de Classes do Software	44
Figura 3.4 - Diagrama de Atividades do software.....	45
Figura 4.1 - Imagens com excesso de sujeira	48
Figura 4.2 - Imagem original, imagem no canal azul e imagem com contraste.....	49
Figura 4.3 - Imagem original e imagem filtrada pelo filtro Gaussiano	49
Figura 4.4 - Imagem filtrada pelo filtro Gaussiano e imagem com contraste	50

Figura 4.5 - Imagem com contraste e imagem no canal azul	50
Figura 4.6 - Imagem no canal azul e imagem filtrada com o filtro Gaussiano	50
Figura 4.7 - Imagem filtrada com filtro Gaussiano e imagem binária	51
Figura 4.8 - Imagem binarizada e imagem com <i>floodfill</i>	51
Figura 4.9 - Tela principal do protótipo	53
Figura 4.10 - Demonstração da abertura da imagem.....	53
Figura 4.11 - Início do diagnóstico.....	54
Figura 4.12 - Diagnóstico positivo para <i>Ascaris lumbricoides</i>	54
Figura 4.13 - Diagnóstico positivo para <i>Trichuris trichiura</i>	55
Figura 4.14 - Diagnóstico negativo para <i>Ascaris lumbricoides</i> e <i>Trichuris trichiura</i>	55

LISTA DE TABELAS

Tabela 4.1 - Intervalo dos valores de área, perímetro e circularidade de cada parasita _____	52
Tabela 4.2 - Resultados totais _____	56
Tabela 4.3 - Resultados problemáticos de amostras de artefatos _____	56
Tabela 4.4 - Resultados problemáticos de amostras de <i>Trichuris trichiura</i> _____	57
Tabela 4.5 - Resultados problemáticos de amostras de <i>Ascaris lumbricoides</i> _____	58
Tabela 5.1 - Resultados das amostras de <i>Trichuris trichiura</i> _____	66
Tabela 5.2 - Resultados das amostras de <i>Ascaris lumbricoides</i> _____	70

LISTA DE ABREVIATURAS E SIGLAS

EPF	Exames Parasitológicos de Fezes
MATLAB	Matrix Laboratory
PUCPR	Pontifícia Universidade Católica do Paraná
PUCRS	Pontifícia Universidade Católica do Rio Grande do Sul
ROI	Region of Interest (Região de Interesse)
SAD	Sistemas de Apoio ao Diagnóstico
UFMG	Universidade Federal de Minas Gerais
UFPEL	Universidade Federal de Pelotas
UFRGS	Universidade Federal do Rio Grande do Sul
UFSC	Universidade Federal de Santa Catarina
UML	Unified Modeling Language
Unicamp	Universidade Estadual de Campinas
Urcamp	Universidade da Região da Campanha

SUMÁRIO

INTRODUÇÃO	12
1 PARASITOLOGIA	14
1.1 Diagnóstico parasitológico	15
1.2 Morfologia dos parasitas	18
2 ANÁLISE DE IMAGENS COMO SAD.....	20
2.1 Captura de imagem.....	21
2.2 Pré-processamento.....	22
2.2.1 Contraste	22
2.2.2 Extração de ruído	23
2.2.3 Filtro passa-baixa.....	24
2.3 Segmentação.....	26
2.3.1 Detecção de Bordas	26
2.4 Seleção da região de interesse (ROI).....	32
2.4.1 Limiarização	33
2.4.2 Afinamento	33
2.4.3 Dilatação	34
2.4.4 Erosão	35
2.4.5 Floodfill	36
2.5 Reconhecimento	36
2.5.1 Análise Morfométrica	37
3 ANÁLISE DO SISTEMA	41
3.1 Características do sistema.....	41
3.2 Diagramação do software	42
4 PROTÓTIPO DO SISTEMA.....	47
4.1 Ambiente	47
4.2 Obtenção das imagens	48
4.3 Problemas na segmentação.....	48
4.4 Melhoria nas imagens obtidas	49
4.5 Identificação dos parasitas.....	52
4.6 Utilização do protótipo	52
4.7 Resultados.....	56
CONCLUSÃO.....	59
REFERÊNCIAS BIBLIOGRÁFICAS	61

ANEXO A	64
ANEXO B	65
ANEXO C	70

INTRODUÇÃO

As parasitoses são um grande problema de saúde pública que ocorre principalmente nos países em desenvolvimento, contribuindo com a mortalidade. Este fato é agravado por problemas econômicos, sociais e de saneamento básico. Atingem principalmente crianças e adolescentes, comprometendo o seu desenvolvimento físico e intelectual. (SILVA, SANTOS, 2001)

Segundo dados da Organização Mundial da Saúde (OMS), estima-se que 3,5 bilhões de pessoas no mundo estão infectadas com um ou mais tipos de parasitas. Conforme a Organização Pan-Americana da Saúde (Opas), 51% da população brasileira está infectada com algum tipo de parasita. No Brasil, são realizados cerca de 20 milhões de exames parasitológicos por ano em órgãos públicos e grande parte da população infectada está nas zonas rurais e nos bolsões de pobreza dos centros urbanos. (ALVES FILHO, 2007)

Atualmente, os exames parasitológicos de fezes são feitos manualmente, sendo afetados por variáveis como humor, atenção e experiência do técnico. Além disso, estudos recentes indicam que a sensibilidade dos diagnósticos convencionais variam de 48% a 76% (ALVES FILHO, 2007), já que todo o processo de análise final depende exclusivamente da avaliação humana, não sendo encontrado, até o momento, formas de automatização para a área de exames de parasitologia. (Tavares, 2008)

Ao observar a falta de automatização na área de exames de parasitologia, verifica-se que existe um novo campo a ser explorado pela tecnologia da informação.

Assim, o *software* desenvolvido é baseado no estudo das características dos parasitas, adquirido através do auxílio de especialistas e de pesquisas na área. Também são utilizadas técnicas de análise de imagens, para identificar ovos de parasitas em imagens de amostras fecais. No momento, foram selecionados dois tipos de parasitas: *Ascaris lumbricoides* e *Trichuris trichiura* para iniciar as pesquisas.

O objetivo do *software* será auxiliar os profissionais e estudantes da área biomédica, contribuindo com a informatização dessa área e, conseqüentemente, com a melhoria do diagnóstico, incentivando a parceria entre diferentes áreas do conhecimento.

Esta pesquisa está sendo desenvolvida em parceria com um professor e um aluno da biomedicina, que estão adquirindo as imagens das amostras e orientando com informações relevantes sobre a parasitologia.

A divisão do trabalho é feita da seguinte forma: no capítulo um são abordados alguns conceitos de parasitologia, estudo dos principais ovos encontrados nos EPF, como são feitos os diagnósticos hoje e a morfometria dos ovos dos parasitas selecionados. No capítulo dois é feita uma breve introdução sobre SAD, segmentação de imagem, extração de ruídos, filtros, detecção de objetos na imagem, cálculos de área, perímetro e circularidade, entre outros. No capítulo três é desenvolvida a análise do sistema baseado no estudo dos capítulos anteriores e na modelagem UML. No capítulo quatro, será abordado todo o processo de desenvolvimento do protótipo, baseado na análise demonstrada no capítulo anterior, bem como, os testes realizados com o protótipo e sua avaliação.

1 PARASITOLOGIA

A parasitologia é a ciência que estuda os organismos que vivem em íntima e estreita dependência de outros seres vivos e que, quando tenham o homem por hospedeiro, podem causar doenças muitas vezes graves (REY, 2002).

No decorrer do século XX, seus progressos foram notáveis e, incorporando métodos e técnicas desenvolvidas em outras áreas, como os da microscopia óptica e eletrônica, pode-se chegar a conhecimentos bastante profundos sobre a sistemática, a estrutura, a fisiologia, a patologia e a ecologia da maioria dos parasitos (REY, 2002).

A parasitologia abrange o estudo de protozoários, helmintos e artrópodes, em cujos grupos situa-se a maioria dos parasitos de importância médica e veterinária. Os protozoários são organismos microscópicos, medindo micrômetros de comprimento. A estrutura básica de todo protozoário é constituída pela membrana, citoplasma e núcleo, os quais, juntamente com as organelas, apresentam características morfológicas e funcionais específicas, conforme sua forma evolutiva e meio a que estejam adaptados. Podem ser esféricos, ovais ou mesmo alongados, alguns são revestidos de cílios, outros possuem flagelos, e ainda existem os que não possuem nenhuma organela locomotora especializada (NEVES, 2006; CIMERMAN, 2001). Já, o termo helminto, abrange quatro grupos, sendo que apenas dois têm interesse para a medicina humana: os platelmintos, ou vermes achatados, e os nematelmintos, ou vermes cilíndricos (CIMERMAN, 2001).

Com o crescimento populacional das últimas décadas, nos países tropicais, e a explosão demográfica, sem melhoria das condições gerais de vida, o diagnóstico desses parasitos passou a ter extrema relevância, visto que sua transmissão também aumentou, principalmente entre as classes economicamente menos favorecidas (REY, 2002).

Segundo estudos já realizados, os helmintos mais encontrados em amostras de fezes positivas, independente da idade estudada, são: *Ascaris lumbricoides*, *Trichuris trichiura* e

ancilostomídeos. Já os protozoários mais encontrados são: *Entamoeba coli*, *Giardia lamblia* e *Endolimax nana*, não necessariamente nesta ordem de prevalência. Estes mesmos estudos relataram que a maior prevalência destes parasitas se deve à forma de infecção de cada um deles (GOMES, 2002; ASSIS *et al*, 2003).

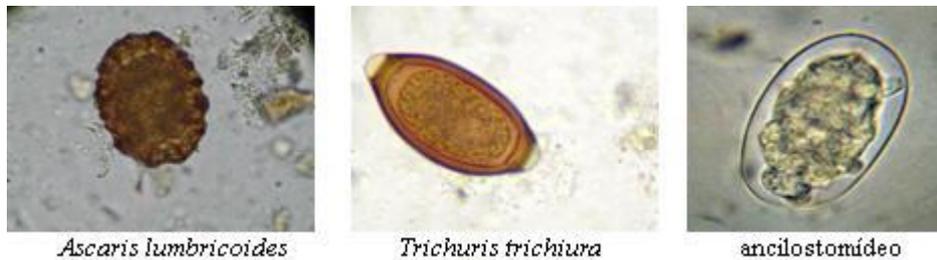


Figura 1.1 - Ovos de nematelmintos mais encontrados

Fonte: Laboratório de Bioanálise da Feevale



Figura 1.2 - Cistos de protozoários mais encontrados

Fonte: UFRGS, 2008; UFMG, 2008

1.1 Diagnóstico parasitológico

Um diagnóstico clínico acurado das infecções parasitárias humanas depende da confirmação laboratorial, para diferenciação específica do agente infeccioso. Inicialmente, é feito o exame clínico, em seguida, o exame parasitológico de fezes (EPF), que é o teste padrão para este diagnóstico. O resultado do EPF tem como objetivo fornecer informações úteis ao diagnóstico; servir como guia ao tratamento; acompanhar e determinar a eficiência do tratamento; trazer informações de valor para estudos epidemiológicos; e fornecer os elementos básicos para corrigir as deficiências nos programas de profilaxia do meio ambiente (DE CARLI, 2001; NEVES, 2006).

Tal exame pode ser realizado através de diversas técnicas já padronizadas em laboratórios clínicos. Embora com diferentes sensibilidades e metodologias, todas se constituem de duas etapas fundamentais: a análise microscópica e análise macroscópica das amostras (NEVES, 2006).

O exame macroscópico permite a verificação da consistência das fezes, do odor, da presença de elementos anormais, como muco e sangue, e de vermes adultos ou partes deles. Já o exame microscópico permite a visualização dos ovos ou larvas de helmintos, cistos, trofozoítos ou oocistos¹ de protozoários. O exame microscópico pode ser quantitativo ou qualitativo. Os métodos quantitativos são aqueles nos quais se faz contagem de ovos nas fezes, permitindo, assim, avaliar a intensidade do parasitismo. Já os métodos qualitativos são os mais utilizados, demonstrando a presença de formas parasitárias sem, entretanto, quantificá-las (NEVES, 2006).

Atualmente, para o diagnóstico laboratorial parasitológico são utilizadas técnicas de concentração que figuram entre os procedimentos de rotina como parte de um exame completo das fezes. Os três principais objetivos dessas técnicas são:

- 1) aumentar o número de cistos, oocistos, ovos ou larvas na preparação;
- 2) eliminar a maioria dos detritos fecais;
- 3) apresentar os organismos em um estado inalterado, facilitando sua identificação.

Essas técnicas são indicadas para separar os cistos e oocistos de protozoários e ovos de helmintos do excesso de detritos fecais através de diferenças específicas de densidade (DE CARLI, 2001).

As técnicas podem utilizar os princípios de flutuação e sedimentação. Nas técnicas de flutuação tem-se a flutuação simples (Willis) e centrífugo-flutuação (Faust). Já nas técnicas de sedimentação, pode-se ter a sedimentação simples, através do Método de Hoffman, Ponz e Janner (HPJ) e centrífugo-sedimentação (Ritchie).

As técnicas de flutuação fundamentam-se no princípio da diferença de densidade específica entre ovos de helmintos, cistos e oocistos de protozoários e o material fecal, a fim de que esses organismos flutuem na superfície dos reagentes com densidade específica. Os procedimentos de flutuação usam reagentes de alta densidade para a concentração dos ovos, cistos e oocistos de parasitos. As principais vantagens apresentadas pela flutuação é a formação na superfície do tubo de uma membrana clara com poucos detritos fecais e a remoção seletiva de ovos e cistos, mesmo quando presentes em pequeno número no bolo fecal, resultando em quantidade maior de organismos de certas espécies. A alta densidade dos

¹ Oocistos: Invólucro resistente dos esporozoários, que encerra inúmeras células resultantes da divisão múltipla de dois gametas conjugantes. (Dicionário Michaelis)

reagentes é a mais significativa desvantagem dos procedimentos de flutuação, pois a morfologia dos ovos e cistos sofre alterações dificultando a sua identificação, mas a flutuação de gorduras e os óleos presentes na amostra também tornam a preparação, algumas vezes, insatisfatória para o exame (DE CARLI, 2001).

Os dois principais objetivos das técnicas de sedimentação são o aumento do número de ovos operculados¹, não operculados, larvas ou cistos e a separação das gorduras e óleos da maioria dos detritos. Nessas técnicas, os organismos são sedimentados igualmente pela gravidade ou centrifugação. A sedimentação apresenta uma ação inversa a flutuação. Os cistos, oocistos, ovos e larvas são retidos no fundo do tubo. A sua maior desvantagem é a grande quantidade de detritos fecais, tornando a identificação dos organismos muito mais difícil do que pelos procedimentos de flutuação. As técnicas de sedimentação foram desenvolvidas para o diagnóstico das enteroparasitoses. Alguns autores recomendam o uso conjunto das técnicas de flutuação e sedimentação na rotina laboratorial; entretanto, esta conduta ainda não é de rotina para a maioria dos laboratórios (DE CARLI, 2001).

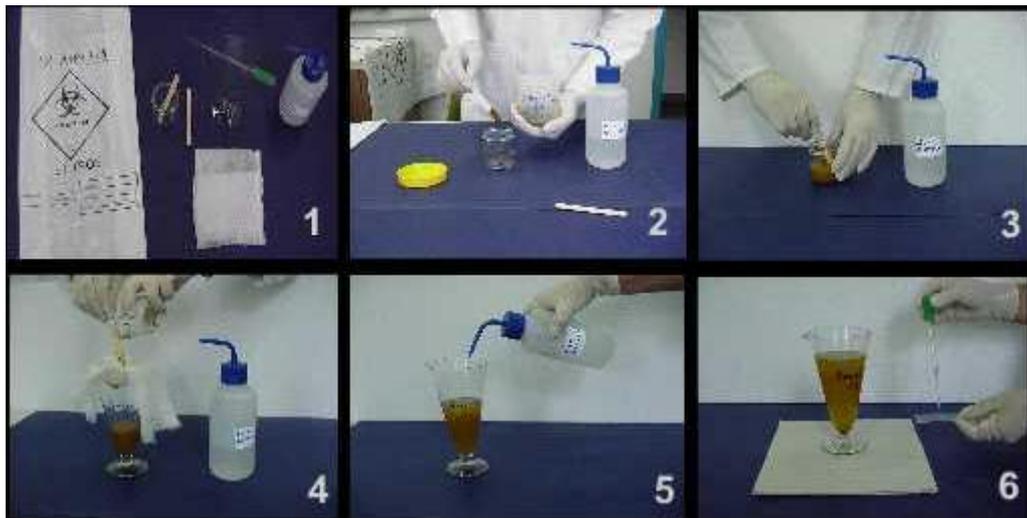


Figura 1.3 - Método de Sedimentação Espontânea

Fonte: HORNINK, 2008

Um diagnóstico incorreto é resultado de dois tipos de erros: de procedimento e de interpretação. Os erros de procedimento são uma consequência do uso incorreto do microscópio, de esfregaços impropriamente preparados, de deficiências no exame de toda a preparação, de uma observação muito rápida das preparações, de falhas no uso dos aparelhos de medida, de uma variedade de técnicas e da falta de experiência para uma pesquisa criteriosa de certas espécies. Os erros de interpretação se devem à falta de conhecimento das

¹Operculados: Provido de opérculo, isto é, com duas tampas nas extremidades. (Dicionário Michaelis)

várias espécies e dos diferentes tipos de artefatos presentes nas fezes; incapacidade para observar que os organismos de certas espécies apresentam uma variedade de características e que, muitas vezes, não se assemelham às figuras e fotografias de atlas, ou desconhecimento do fato de que os parasitos com diagnóstico duvidoso deverão ser estudados até a sua identificação, ou encaminhados a um especialista, ou ainda, há a necessidade de amostra adicional do paciente (DE CARLI, 2001).

Atualmente, as técnicas realizadas no setor de parasitologia são exclusivamente manuais, sendo afetadas possivelmente por variáveis como atenção e experiência do técnico. Além disso, estudos recentes indicam que a sensibilidade dos diagnósticos convencionais varia de 48% a 76% (Unicamp, 2007), já que todo o processo de análise final depende exclusivamente da avaliação humana, não sendo encontrado até o momento formas de automatização para o setor de análise de exames de parasitologia.

1.2 Morfologia dos parasitas

Neste trabalho foram escolhidos dois tipos de nematelmintos para iniciar o estudo de um sistema de auxílio ao diagnóstico parasitológico. Os parasitas selecionados foram *Ascaris Lumbricoides* e *Trichuris trichiura*. A escolha dos parasitas foi baseada na morfologia dos ovos, pois são bastante diferenciados e também por serem comumente encontrados em EPF.

A identificação desses nematelmintos é determinada microscopicamente, por profissional habilitado, de acordo com a morfologia dos ovos. No caso do *Trichuris trichiura*, possuem o aspecto de barril, de cor marrom, com dois tampões hialinos nas extremidades. Medem em torno de 50 µm de comprimento X 22 µm de largura (NEVES, 2006).

A figura a seguir apresenta um ovo de *Trichuris trichiura*.



Figura 1.4 - Ovo de *Trichuris trichiura*
Fonte: Laboratório de Bioanálise da Feevale

Já os ovos de *Ascaris lumbricoides* apresentam-se frequentemente nas seguintes formas: fértil, infértil, decorticado e larvado. Os ovos férteis são arredondados, envolvidos

por uma membrana de duplo contorno, rodeados por uma camada albuminosa rugosa com aspecto mamilonado, com projeções na superfície semelhante a um “abacaxi arredondado” e medem cerca de 60µm de comprimento por 45µm de largura. Já os ovos inférteis são mais alongados, maiores que os férteis (85-95µm por 43-47µm) e com a membrana mamilonada irregular. Os ovos decorticados são ovos férteis normais, mas não tem membrana mamilonada, o que pode dificultar o seu diagnóstico. Já os ovos larvados possuem a larva em seu interior, são desprovidos de membrana mamilonada e são arredondados (NEVES, 2006). Assim que os ovos são postos pelas fêmeas no interior do intestino delgado possuem a cor acinzentada, porém, no trajeto, adquirem pigmentos biliares, sendo eliminados com a cor castanha.

A figura a seguir apresenta os tipos de ovos de *Ascaris lumbricoides*.

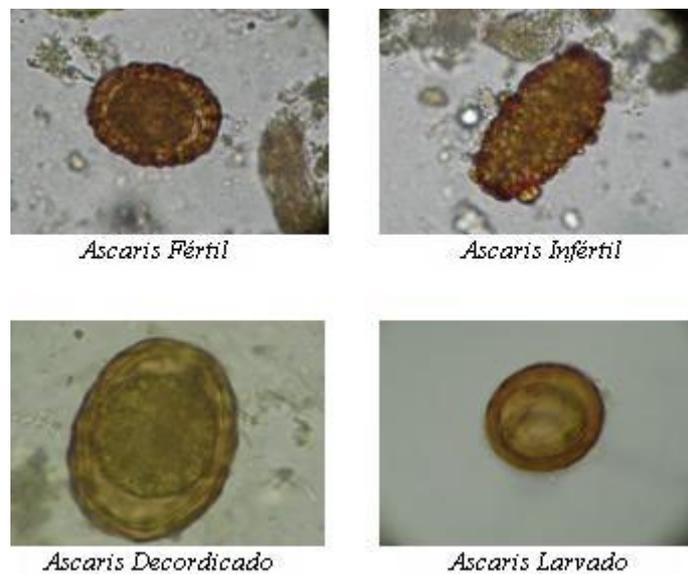


Figura 1.5 - Ovos de *Ascaris lumbricoides*
Fonte: Laboratório de Bioanálise da Feevale

Com base neste breve estudo da parasitologia, o próximo capítulo buscará técnicas de análise de imagens que auxiliarão no desenvolvimento deste projeto.

2 ANÁLISE DE IMAGENS COMO SAD

Na área médica, a computação gráfica vem se salientando em relação a outras áreas da TI. Segundo o Instituto de Física da UFRGS (2000), o uso de computadores na medicina tem se desenvolvido bastante, mas precisa ainda progredir muito. Os computadores são utilizados, na maioria das vezes, apenas para a aquisição de imagens. Porém, é o uso da computação gráfica que auxiliará na quantização da imagem e no tratamento para a melhor extração das informações. (CARDOSO, 2005, FALSARELLA, 2004)

A sigla SAD pode significar Sistemas de Apoio à Decisão ou também Sistemas de Apoio ao Diagnóstico. Esses sistemas contribuem para a tomada de decisões. Podem ser construídos para várias áreas do conhecimento, como, por exemplo, para a gerência de uma empresa, para o diagnóstico médico, entre outras.

Os SAD buscam informações para resolver determinado problema e, a partir dessas informações, geram um resultado que auxilia o usuário na tomada de decisão. Algumas características do SAD são:

- Capacidade de encontrar a melhor solução de problemas simples (otimização) e de encontrar uma solução considerável para problemas complexos (heurística);
- Pode fazer modificações hipotéticas aos dados do problema para observar os impactos nos resultados;
- Suporte para diversos níveis na tomada de decisão. (JÚNIOR, 2006)

Os SAD são amplamente utilizados na medicina. Uma das razões é a grande quantidade de informação que os profissionais dessa área devem saber para exercer as suas funções adequadamente. Outro motivo deve-se ao aumento da qualidade e rapidez na medicina, onde esses sistemas são capazes de auxiliar no diagnóstico de pacientes. (JÚNIOR, 2006)

Este projeto busca informatizar a análise de imagens médicas de EPF, extraindo e analisando essas informações, gerando um resultado. Porém, isto não significa que os profissionais da área da saúde não precisarão participar do diagnóstico. Na verdade, estes deverão verificar o resultado gerado pelo sistema auxiliar, criando um diagnóstico com maior precisão, rapidez e de forma mais simplificada.

Na projeção de um sistema de apoio ao diagnóstico em parasitologia é necessária a análise das imagens dos EPF. Para isso propõem-se as seguintes etapas a serem desenvolvidas:

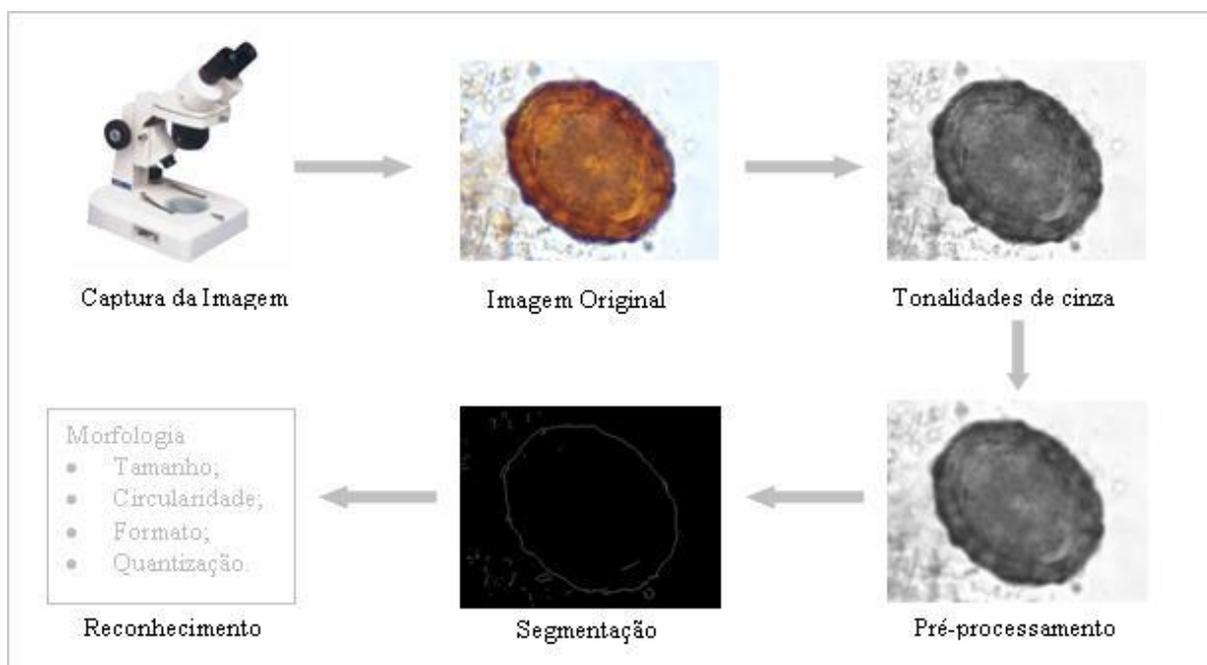


Figura 2.1 - Fluxo de atividades do sistema proposto

2.1 Captura de imagem

Existem vários métodos de captura da imagem, dentre os quais pode ser citados: câmeras, filmadoras, equipamentos como ressonância magnética, dentre tantos outros.

Neste trabalho a aquisição das imagens foi feita através da seleção de imagens microscópicas, capturadas por uma câmera fotográfica acoplada ao microscópio utilizado para análises de EPF, localizado no Centro Universitário Feevale, e posteriormente a imagem foi transferida para um computador, formando um banco de imagens.

A partir deste banco de imagens, foi projetado um *software* que identifica ovos de parasitos *Ascaris Lumbricoides* e *Trichuris trichiura*, por meio da comparação dessas imagens

com o banco de dados, utilizando também, características específicas de morfologia, tamanho e coloração dos parasitos em questão.

2.2 Pré-processamento

Após a aquisição da imagem, o sistema aplica técnicas de melhoramento da imagem para acentuar suas características, realçando áreas de interesse. Isto é necessário quando a imagem sofre perda da qualidade através de ruído, perda de contraste, borramento, distorções causadas pelos equipamentos de captura e condições de iluminação.

O realce na imagem pode ser gerado através de alterações nas intensidades dos *pixels* que se situam em intervalos específicos de nível de cinza. Pode ser baseado em técnicas no domínio da frequência ou espacial. (PEDRINI, SCHWARTZ, 2008, p.107)

Uma das técnicas de realce é a alteração no contraste da imagem, que será apresentado a seguir.

2.2.1 Contraste

O contraste pode melhorar a visualização de detalhes da imagem, isto é, melhorar a qualidade da mesma. (PEDRINI, SCHWARTZ, 2008, p. 106)

O intervalo de contraste de uma imagem é a diferença entre os valores de intensidade máximo e mínimo que os *pixels* de uma imagem possuem. Assim, baseado nos dispositivos de visualização, que normalmente variam de [0, 255], podem ser mapeados os intervalos de níveis de cinza da imagem original. De acordo com Conci (2008), a função que representa essa transformação dita como T, através dos níveis de cinza, pode ser descrita como:

$g = T(f)$, onde f representa os níveis de cinza da imagem original e g representa o nível de cinza da imagem modificada. Dessa forma, o contraste na nova imagem será maior, pois haverá um escurecimento dos *pixels* de níveis mais baixos (próximo de 0) e um clareamento dos *pixels* de níveis mais altos (próximos de 255). (CONCI, AZEVEDO, LETA, 2008)

Uma função linear pode ser representada pela seguinte equação:

$g = af + b$, onde a representa o intervalo da escala dos níveis de cinza e b ajusta o brilho da imagem. Portanto, se o valor de a for igual a 1, a imagem permanecerá com o

mesmo intervalo de nível de cinza, mas se a for menor que 1, o intervalo será comprimido, se for maior que 1, o intervalo será expandido. (PEDRINI, SCHWARTZ, 2008, p.107)

A transformação linear inversa também é comum, neste caso produz um negativo da imagem original. Para ser obtida, pode ser utilizada a função $s = T(r)$. A idéia é reverter o preto para o branco e vice-versa. Assim, a intensidade da imagem de saída diminui à medida que a imagem de entrada aumenta. (GONZALEZ, WOODS, 2000, p. 119)

O realce de qualquer ponto da imagem depende apenas do nível de cinza daquele ponto, assim as técnicas nesta categoria são denominadas processamento ponto-a-ponto. (GONZALEZ, WOODS, 2000, p. 117)

2.2.2 Extração de ruído

Segundo Shapiro (2000), um ruído é a variação brusca de um *pixel* em relação aos seus *pixels* vizinhos. Uma pequena região da imagem pode não ser relevante para o seu processamento ou pode estar suprimindo detalhes importantes, atrapalhando a extração de informações da imagem. Por isso, para melhorar a qualidade das imagens, são utilizadas técnicas de remoção de pequenas regiões, isto é, extração de ruído. Nestes casos podem ser utilizadas máscaras, e através delas, podem ser realizadas comparações do *pixel* central com seus *pixels* vizinhos e, caso seja necessário, trocar o seu valor.

As máscaras podem ser relacionadas utilizando uma vizinhança de 4 ou de 8 vizinhos. No caso de 4, são considerados os *pixels* vizinhos superior, inferior e laterais do *pixel* central. No caso da vizinhança de 8, além dos 4 mencionados anteriormente, utiliza-se os *pixels* das diagonais principal e secundária. (CONCI, AZEVEDO, LETA, 2008, p. 210)

Numa imagem binária, quando um *pixel* claro é encontrado numa região escura é chamado de *salt* e quando um *pixel* escuro é encontrado numa região clara, então é chamado de *pepper*. Normalmente, os *salt* e *pepper* são classificados erros resultantes da variação da superfície ou da iluminação do material, ou também ruídos da conversão de analógico para digital. (SHAPIRO, STOCKMAMN, 2000, p.151)

Outra forma de extrair ruídos é através da remoção de componentes. Para isso, o algoritmo que processará a imagem deverá utilizar os recursos computacionais como, por exemplo, análise de componentes com poucos *pixels*.

Normalmente, as imagens são compostas por estruturas ideais, mas junto tem-se ruídos aleatórios e artificiais, os quais precisam ser removidos. Por exemplo, uma região, formada por *pixels* de valor uniforme com valor $g_r + N(0, \sigma)$, onde g_r espera um nível de cinza para as condições ideais da imagem e $N(0, \sigma)$ é o filtro gaussiano de média 0 e desvio padrão σ . Assim, o filtro gaussiano está sendo adicionado para criar uma imagem ideal no intervalo de cinza [0, 255]. (SHAPIRO, STOCKMAMN, 2000, p.152)

2.2.3 Filtro passa-baixa

Os filtros de passa-baixa são utilizados para a suavização das imagens. Assim, o nível de cinza de cada *pixel* é substituído pela média dos níveis de cinza da sua vizinhança. Esses filtros eliminam ou diminuem os componentes de alta frequência da imagem, enquanto deixam os de baixa frequência inalterados. O efeito resultante é o borramento da imagem. (GONZALEZ, WOODS, 2000, p. 135; MARTINO, p. 378)

O borramento pode ser utilizado no pré-processamento da imagem, pois remove pequenos ruídos antes da extração de grandes objetos, e conexão de linhas e curvas. (GONZALEZ, WOODS, 2000, p. 136)

De acordo com Conci (2008), o uso de máscaras espaciais para o processamento de imagens é chamado filtragem espacial. Quando for utilizado um filtro espacial de passa-baixa, observa-se que, quanto maior for o tamanho da máscara, maior será o borramento. Alguns filtros passa baixa são apresentados a seguir.

2.2.3.1 Filtro da Média

Neste tipo de filtro é calculada a média dos *pixels* de uma vizinhança, onde cada *pixel* é substituído pelo valor médio de seus vizinhos. Isto pode reduzir as variações de nível de cinza dos *pixels* vizinhos, por isso, para evitar borramento nos contornos da imagem, pode-se realizar a suavização em apenas algumas regiões da imagem. (FACON, p.33)

No filtro da Média são utilizadas máscaras, porém o seu tamanho depende do tamanho e da quantidade de ruídos da imagem.

2.2.3.2 Filtro Gaussiano

Na suavização por filtragem Gaussiana é utilizada a distribuição como uma função de ponto de espalhamento, que é obtida através de convolução, apresentando um borramento na imagem. (SHAPIRO, STOCKMAMN, 2000, p.154)

O filtro Gaussiano é similar ao filtro médio, porém utiliza um *kernel* diferente que representa a forma da distribuição Gaussiana.

O desvio padrão do *pixel* central em relação aos seus vizinhos é computado, obtendo um novo valor para o *pixel*, que é calculado pela aproximação do filtro de Gauss, através da seguinte fórmula:

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

Onde $G(x, y)$ representa o novo valor do *pixel*, σ representa o desvio padrão da distribuição, x é a posição horizontal e y é a posição vertical do *pixel*.

De acordo com Gattass (2005), esta função tem duas propriedades importantes para um filtro: simetria e a integral em todo o seu domínio é igual a 1.

Na notação discreta, a função pode ser representada pelas matrizes:

$$\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \qquad \frac{1}{273} \begin{bmatrix} 1 & 4 & 7 & 4 & 1 \\ 4 & 16 & 26 & 16 & 4 \\ 7 & 26 & 41 & 26 & 7 \\ 4 & 16 & 26 & 16 & 4 \\ 1 & 4 & 7 & 4 & 1 \end{bmatrix}$$

A escolha da matriz influencia no resultado desejado. Pode-se dizer que a distribuição representa a média ponderada de cada *pixel* em relação a sua vizinhança, por isso, este método apresenta melhores resultados que um filtro médio de igual tamanho. Neste caso, o grau de suavização é determinado pelo desvio-padrão da imagem. Portanto, maiores desvios requerem maiores máscaras para serem representados. (MORAES, 2006, p. 5)

A seguir, é apresentado um exemplo da aplicação do operador gaussiano em uma imagem de lâmina de parasitologia com ovo de *Ascaris lumbricoides*.

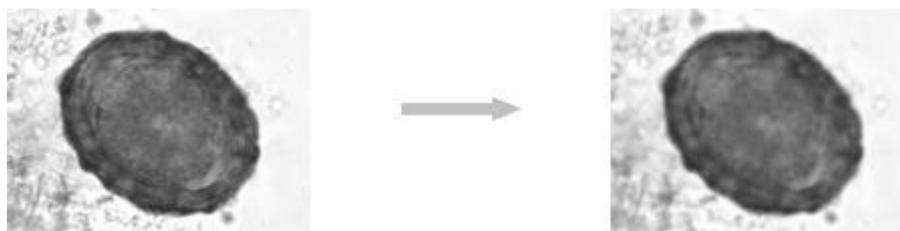


Figura 2.2 - Imagem em escala de cinza e Imagem filtrada com o filtro Gaussiano

2.2.3.3 Filtro da Mediana

Esses filtros são utilizados quando o padrão de ruídos apresenta componentes fortes do tipo “espigada” e a característica que deve ser mantida é a nitidez das bordas. (GONZALEZ, WOODS, 2000, p. 137)

Os filtros por mediana não são lineares. Assim, no filtro da mediana, é criada uma lista ordenada com o valor de todos os *pixels* vizinhos nos níveis de cinza, onde é selecionada a posição média da lista.

Numa imagem com duas regiões com intensidades de *pixels* diferenciados, teremos um borramento na divisa dessas regiões. Para diminuir este borramento, os *pixels* que o compõem serão substituídos pelo valor da mediana. Assim, o principal objetivo da filtragem pela mediana é forçar os pontos com intensidades distintas a ficarem semelhantes aos seus vizinhos, eliminando os espigamentos. (GONZALEZ, WOODS, 2000, p. 138)

2.3 Segmentação

Uma imagem possui várias informações, porém, para extraí-las é necessário particionar os conjuntos de dados de entrada em objetos relevantes para a aplicação. Portanto, é fundamental que o processo de segmentação da imagem identifique corretamente a localização, as topologias e as formas dos objetos. (PETRINI, SCHWARTZ, 2008)

As segmentações convencionais são baseadas nas propriedades básicas dos níveis de cinza da imagem, buscando descontinuidade e similaridades.

2.3.1 Detecção de Bordas

A borda é o limite entre duas regiões. Pode ser definido através dos níveis de cinza das regiões. Portanto, são caracterizadas por transições abruptas de níveis de cinza, pois

através dos pontos de picos da imagem podem ser detectadas as intensidades diferentes em regiões da imagem. Normalmente, são esses pontos que formam as bordas entre os diferentes objetos da imagem. (SHAPIRO, STOCKMAMN, 2000, p.156)

Os filtros de detecção de borda ou filtros de passa-altas (FPA) são utilizados para eliminar feições de baixa frequência e realçar as de alta frequência, dando destaque aos detalhes finos da imagem. Para fazer esse realce, são utilizadas máscaras.

O tamanho da máscara influencia no resultado. Quanto menor forem as dimensões da máscara, menos detalhes serão realçados.

Muitos detectores de bordas são baseados no gradiente, que é definido através da seguinte fórmula:

$$|G| = \sqrt{G_{x^2} + G_{y^2}}$$

Grande parte dos detectores de borda utiliza operadores de primeira e segunda ordem. Esses operadores ressaltam os contornos dos objetos e aumentam o ruído. Assim, os operadores de borda utilizam alguma suavização da imagem antes de aplicar o operador de detecção de borda. (BUENO, 2000)

Para usar os operadores de bordas é importante entender o termo convolução. Esta é a técnica de passar uma matriz ou *kernel* sobre uma imagem para extrair informações da mesma.

A seguir, serão apresentados alguns detectores de bordas testados em imagens de exames de parasitologia.

2.3.1.1 Sobel

O operador de Sobel é uma técnica de detecção de bordas que realça as bordas da imagem em certas direções, baseando-se na aplicação do gradiente, dependendo da implementação do filtro. Possui uma propriedade que permite detectar se um *pixel* pertence ou não a uma borda, independente dos *pixels* vizinhos pertencerem ou não a mesma borda, isto é, cada *pixel* é processado de forma independente. Este operador fornece a direção do aumento de intensidade e a taxa de alteração na direção verificada. (BASTOS, 2000; PINTO, 2007)

Esta técnica de detecção de bordas é bastante utilizada, pois o seu algoritmo é de fácil implementação e a sua execução é rápida, porém, é muito sensível a ruído e iluminação, também é bastante dependente do parâmetro de *threshold*. Isto influencia na qualidade da imagem resultante, pois é difícil estabelecer um parâmetro que atenda diferentes casos, sem perder características importantes e que exclua ruídos da imagem original.

São utilizadas as seguintes máscaras para encontrar os gradientes, vertical e horizontal, das bordas para o operador Sobel:

$$M_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad M_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$

Um exemplo da aplicação do detector de bordas de Sobel, sobre uma imagem de lâmina de parasitologia com ovo de *Ascaris lumbricoides* é apresentado a seguir.

A função utilizada para detectar a borda da imagem através do operador Sobel no Matlab é $imagemSobel = edge(imagem, 'sobel')$. O resultado é representado na imagem a seguir.

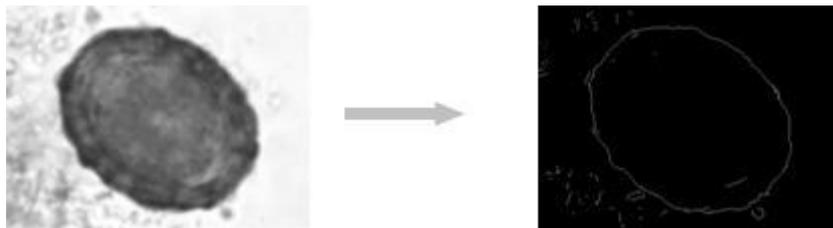


Figura 2.3 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Sobel sem limiar

2.3.1.2 Prewitt

O operador de Prewitt diferencia e suaviza a imagem, atenuando os efeitos negativos do ruído. Utiliza duas máscaras que são convolucionadas com a imagem original. Este operador é muito semelhante ao operador de Sobel, o que os diferencia são os pesos dos pontos vizinhos do *pixel* central, onde Prewitt possui menos peso, produzindo bordas diagonais mais atenuadas.

As máscaras na horizontal e na vertical para o operador de Prewitt são:

$$M_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad M_y = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$$

Um exemplo da aplicação do detector de bordas de Prewitt, sobre uma imagem de lâmina de parasitologia com ovo de *Ascaris lumbricoides* é apresentado a seguir.

A função utilizada para detectar a borda da imagem através do operador Prewitt no Matlab é $imagemPrewitt = edge(imagem, 'prewitt')$. O resultado é apresentado na imagem a seguir.

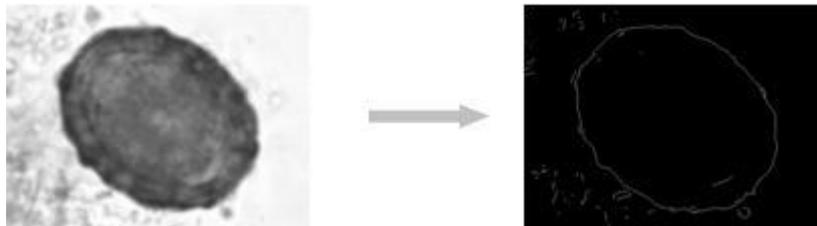


Figura 2.4 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Prewitt sem limiar

2.3.1.3 Roberts

O método de Roberts é o detector de bordas mais antigo. Possui algumas desvantagens, uma delas é que certas arestas são mais realçadas que outras, mesmo com magnitudes iguais.

O resultado de sua aplicação pode ser uma imagem com altos valores de cinza em regiões com limites bem definidos e baixos valores em regiões com limites suaves.

O gradiente de Roberts utiliza máscaras 2x2 para encontrar diferenças nas direções x e y .

As máscaras de convolução utilizadas para o operador de Roberts são:

$$M_x = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix} \quad M_y = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$$

Um exemplo da aplicação do detector de bordas de Roberts, sobre uma imagem de lâmina de parasitologia com ovo de *Ascaris lumbricoides* é apresentado a seguir.

A função utilizada para detectar a borda da imagem através do operador Roberts no Matlab é $imagemRoberts = edge(imagem, 'roberts')$. O resultado é apresentado na imagem a seguir.



Figura 2.5 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Roberts sem limiar

2.3.1.4 Laplace

A exigência do laplaciano digital é que o coeficiente associado com o *pixel* central seja positivo e que os *pixels* externos sejam negativos. Este filtro não é muito utilizado para a detecção de bordas, pois é muito sensível a ruído e produz bordas duplas, sendo incapaz de detectar a direção da borda. (GONZALEZ, WOODS, 2000, p. 301)

A máscara utilizada para o operador de Laplace é:

$$M = \begin{bmatrix} 0 & -1 & 1 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

Um exemplo da aplicação do detector de bordas de Laplace, sobre uma imagem de lâmina de parasitologia com ovo de *Ascaris lumbricoides* é apresentado a seguir.



Figura 2.6 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Laplace sem limiar

2.3.1.5 Canny

O detector de bordas de Canny foi desenvolvido através dos trabalhos de Marr e Hildreth. Ele suaviza os ruídos da imagem para atenuar as bordas fracas e detecta as bordas das regiões. Utiliza o operador gaussiano de primeira derivada. De acordo com a função gaussiana em uma dimensão e suas duas derivadas, é mais simples combinar os estágios de detecção e suavização em uma convolução em 1-D, cada convolução com a primeira derivada da função ou com a segunda derivada considerando o cruzamento de zeros. (BUENO, 2000)

O algoritmo de Canny possui algumas características como diminuir a distância entre a borda encontrada e a borda real, bem como encontrar bordas de objetos com maior precisão que os outros algoritmos. Ele passa por quatro etapas: a uniformização da imagem, onde a imagem deve passar por uma função gaussiana bidimensional; a diferenciação, onde é calculado o gradiente da superfície uniforme da imagem convolucionada; a omissão de pontos de mínima intensidade, isto é, será omitido o *pixel* de uma região que possuir valor menor do que os valores dos *pixels* vizinhos e limiarização da borda (*threshold*). (BUENO, 2000)

Um exemplo da aplicação do detector de bordas de Canny, sobre uma imagem de lâmina de parasitologia com ovo de *Ascaris lumbricoides* é apresentado a seguir.

A função utilizada para detectar a borda da imagem através do operador Canny no Matlab é `imagemCanny = edge(imagem, 'canny')`. O resultado é apresentado na imagem a seguir.

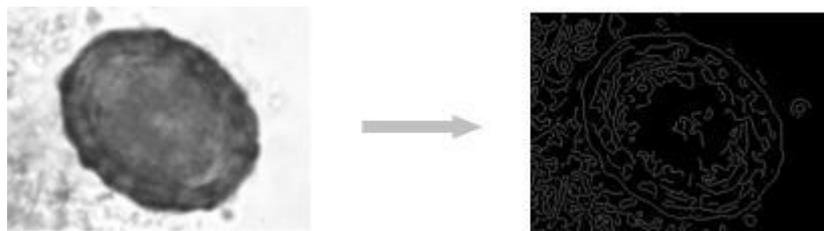


Figura 2.7 - Imagem filtrada pelo filtro Gaussiano e imagem aplicada Canny sem limiar

A partir dos estudos dos detectores de borda abordados anteriormente, será apresentado um comparativo dos algoritmos utilizados.

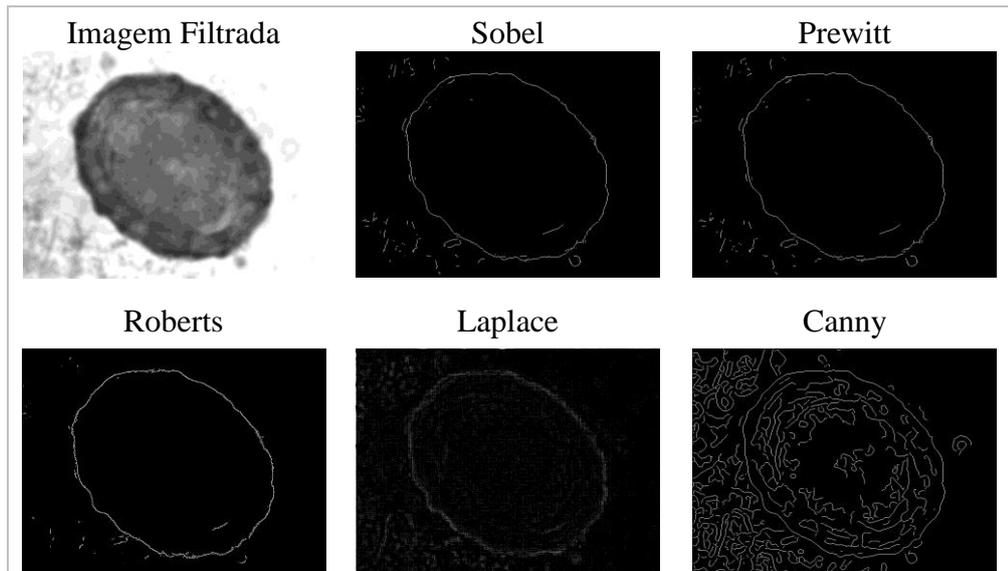


Figura 2.8 - Imagem filtrada e detectores de bordas

Com base na observação das imagens anteriores, pode-se verificar que a imagem resultante da aplicação do operador de Canny detecta mais detalhes que os outros operadores. Porém, os algoritmos de Sobel, Prewitt e Roberts definem claramente a fronteira da figura.

Após a segmentação, pode-se analisar a imagem resultante para extrair as regiões de interesse e, conseqüentemente, o maior número de informações.

2.4 Seleção da região de interesse (ROI)

A morfologia trata da forma e estrutura de um ou mais objetos. Este conceito é utilizado na computação gráfica através da morfologia matemática como uma ferramenta para a extração de componentes de imagens que sejam úteis na representação da descrição da forma e de outras características de uma região, como fronteiras, esqueletos e o fecho convexo. (GONZALEZ, WOODS, 2000, p. 369)

As técnicas morfológicas são utilizadas no pré e no pós-processamento, como, por exemplo, filtragem morfológica, afinamento e poda (*pruning*). (GONZALEZ, WOODS, 2000, p. 369)

A linguagem da morfologia das imagens é baseada na teoria dos conjuntos. Assim, a morfologia oferece uma abordagem unificada que contribui na resolução de vários problemas de processamento de imagem. (GONZALEZ, WOODS, 2000, p. 370)

2.4.1 Limiarização

De acordo com Gonzalez (2000), a limiarização é baseada nos níveis de cinza do histograma da imagem. Supondo que uma imagem $f(x,y)$, composta por objetos claros num fundo escuro possua os *pixels* dos objetos e do fundo com níveis de cinza bastante diferenciados, esses *pixels* poderão ser classificados em dois grupos dominantes. Assim, para extrair os objetos da imagem, pode ser selecionado um limiar T que separe esses grupos. A lógica a ser seguida é: para cada ponto (x,y) tal que $f(x,y) > T$, o *pixel* receberá o valor de um ponto do objeto, caso contrário, o valor do fundo da imagem.

A limiarização também pode ser multinível, isto é, podem ser criados mais de um grupo para a imagem. Porém, este tipo de limiarização é menos confiável, pois é difícil estabelecer múltiplos limiares que isolem as regiões de interesse, principalmente com um grande número de limiares.

A limiarização é uma operação que envolve testes de função T :

$T = T[x, y, p(x, y), f(x, y)]$, onde $f(x, y)$ é o nível de cinza no ponto (x, y) e, $p(x, y)$ é alguma propriedade local desse ponto. Assim, uma imagem limiarizada $g(x, y)$ é definida como

$$g(x,y) = \begin{cases} 1 \rightarrow f(x,y) > T \\ 0 \rightarrow f(x,y) \leq T. \end{cases}$$

Dessa forma, os *pixels* $g(x, y)$ que possuírem o valor 1, corresponderão ao objeto, e os que tiverem o valor 0, ao fundo da imagem.

2.4.2 Afinamento

Num reconhecimento de imagem, o afinamento geralmente é feito antes da interpretação dos dados para fornecer informações consistentes e suficientes. Assim, o reconhecimento poderá ter uma maior qualidade. (GUILHERME, 2007, p. 1)

Uma característica bastante importante dos métodos de afinamento é a conectividade. Dois *pixels* são conexos se existir uma sequência de *pixels* que os ligue. Esta sequência é definida pelas características comuns dos *pixels*. (GUILHERME, 2007, p. 9)

Os algoritmos de alinhamento caracterizam-se pela repetição do processo de eliminação dos pontos desnecessários, gerando um esqueleto do objeto. Dessa forma, o objeto

simplificado deverá possuir a largura de um único *pixel* e possuir informações como posição, orientação, regiões e o comprimento dos segmentos da imagem original.

As técnicas de afinamento são definidas em dois grupos principais: paralelos e sequenciais. Esses algoritmos são baseados na análise dos *pixels*, que verifica quais *pixels* podem ser excluídos.

De acordo com Guilherme (2007), nos algoritmos paralelos, a exclusão de um *pixel* na n -ésima posição depende dos *pixels* da interação $(n-1)$, assim todos os *pixels* podem ser analisados individualmente. Já nos algoritmos sequenciais, a análise possui uma série de operações para cada interação, portanto, o *pixel* somente será excluído na n -ésima interação, quando todas estiverem satisfatórias.

As técnicas sequenciais excluem camadas de *pixels* dos objetos da imagem até encontrar apenas um *pixel* de largura. Esta análise pode ser feita de duas formas: através de varredura (*raster scans*) que varre a imagem em determinadas direções ou de verificação do contorno (*contour following*) que segue os contornos dos objetos.

Nas técnicas de afinamento paralelas, os *pixels* são excluídos independentemente dos resultados obtidos na interação anterior, permitindo que o algoritmo seja implementado num sistema de processamento paralelo.

Os dois tipos de técnicas possuem vantagens e desvantagens, a escolha do algoritmo dependerá do tipo de aplicação. Os algoritmos sequenciais possuem um processamento maior, porém, produzem um esqueleto mais fiel da imagem original, mantendo mais a conectividade e a topologia do objeto. Nos algoritmos paralelos, o processamento é mais rápido, porém, o resultado tem menor qualidade que os algoritmos sequenciais. (GUILHERME, 2007, p. 10)

2.4.3 Dilatação

A dilatação é uma técnica que se baseia na aplicação de um elemento estruturante sobre um conjunto de pontos de uma imagem, adicionando informações na vizinhança destes pontos. Assim, este elemento passa sobre os *pixels* vizinhos numa proporção que varia conforme as dimensões do elemento. Este tipo de operação é utilizada, normalmente, para preencher colunas e intervalos indesejáveis.

O processo de dilatação começa na obtenção da reflexão de um elemento estruturante em torno da sua origem, seguido da translação dessa reflexão por x . (GONZALEZ, WOODS, 2000, p. 371)

A dilatação de imagens de tons de cinza pode ser definida pela seguinte fórmula:

$$(A \oplus B) = \max \{A(i - x, j - y) + B(x, y) \mid (i - x, j - y) \in A, (x, y) \in B\}$$

Onde B corresponde ao elemento estruturante e A a imagem na escala de cinza. O cálculo é feito através do posicionamento da origem do elemento estruturante no primeiro *pixel* da imagem. Após, é somado cada par de *pixels* do elemento estruturante e da imagem. Assim, acha-se o valor máximo de todas essas somas e armazena-se o *pixel* na imagem resultante. Este processo deverá ser repetido para cada *pixel*.

2.4.4 Erosão

A erosão de uma imagem é definida pela aplicação de um elemento estruturante sobre um conjunto de pontos de uma imagem, removendo informações irrelevantes como ruídos e abrindo intervalos ou lacunas em regiões de conexão indesejada. Na verdade, é o inverso da dilatação, remove informações da imagem.

O cálculo da erosão em imagens na escala de cinza pode ser demonstrado pela seguinte fórmula:

$$(A \ominus B) = \min \{A(i - x, j - y) - B(x, y) \mid (i - x, j - y) \in A, (x, y) \in B\}$$

Onde B representa o elemento estruturante e A a imagem na escala de cinza. O processo inicia-se posicionando a origem do elemento estruturante no primeiro *pixel* da imagem original. Após, calcula-se a diferença de cada par de *pixels* do elemento estruturante e da imagem, encontrando o valor mínimo das diferenças. O valor é armazenado na imagem resultante. Este processo é repetido para cada *pixel* da imagem de entrada.

2.4.5 Floodfill

O *floodfill* é um algoritmo recursivo de preenchimento de regiões. Ele faz uma rasterização buscando regiões conexas, que são definidas a partir da vizinhança de um *pixel*. Assim, os *pixels* vizinhos que atendam a um critério determinado, deverão ter a sua antiga coloração alterada para uma a nova. (LOPES, 2005)

A seguir, será mostrado um exemplo de aplicação do *floodfill*, no qual todas as regiões de coloração vermelha deverão ser substituídas pela coloração amarela.

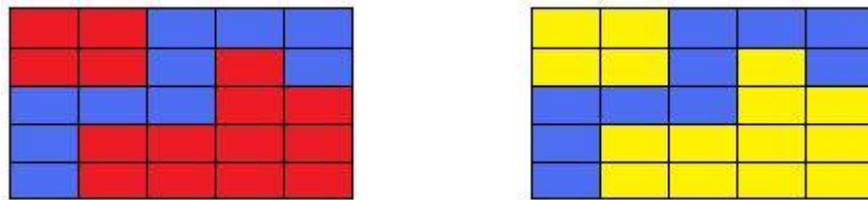


Figura 2.9 - Aplicação de *floodfill* para encontrar as sementes de cada região

Assim, é possível determinar os pontos sementes de cada região, assim como a área. Após, essa definição, podem-se aplicar colorações nas diferentes regiões, a partir do ponto semente definido.

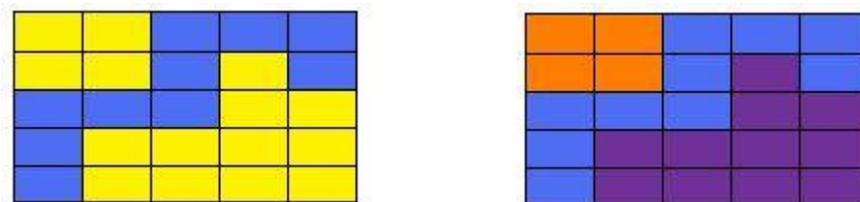


Figura 2.10 - Aplicação de *floodfill* a partir dos *pixels* sementes

Na figura anterior, é demonstrada a aplicação do *floodfill* utilizando os *pixels* sementes encontradas no exemplo anterior, no qual, o critério é definido para que a menor região tenha a sua coloração alterada para laranja e a maior para a coloração roxa.

O algoritmo foi implementado em C# e está disponível no anexo A.

2.5 Reconhecimento

Após a segmentação da imagem, os agrupamentos resultantes de *pixels* segmentados são representados num formato adequado para o processamento. A imagem resultante pode ser representada pelas suas características externas (fronteira entre os objetos) ou pelas suas

características internas (os *pixels* que compõem a região). Normalmente, a representação externa é escolhida quando as características necessárias para o processamento estão voltadas na forma. A representação interna é utilizada quando as propriedades necessárias estão voltadas na cor e na textura. Dessa forma, é possível obter dados relevantes a uma determinada aplicação, como atributos das regiões e objetos destacados. (GONZALEZ, WOODS, 2000, p. 345)

As características mais comuns encontradas são: o número total de objetos, dimensões, geometria, propriedades de luminosidade e textura. Já as características dimensionais são: área, perímetro, centro de gravidade, larguras máximas e mínimas, comprimentos, entre outros. Estas podem auxiliar na descrição das formas dos objetos, como circularidade, retilinearidade, concavidade, eixos principais, etc.

As propriedades de luminosidade e textura podem ser obtidas através da imagem original antes da sua binarização, utilizando as informações das posições dos objetos que foram adquiridas pela segmentação da imagem. Assim, estas propriedades ajudam a extrair colorações, níveis de intensidade média e desvio padrão das bandas da região, entre outros.

Após a aquisição das características da imagem, deverão ser implementadas técnicas para distinguir os objetos da imagem. Este processo pode ocorrer em dois momentos, o primeiro consiste em verificar se as características do objeto correspondem as características de um grupo, numa base de imagens. No segundo, os objetos são apresentados ao sistema, que irá comparar suas características com classes previamente estabelecidas. (CONCI, AZEVEDO, LETA, p. 56)

2.5.1 Análise Morfométrica

A análise morfométrica é baseada na forma, no tamanho, nos níveis de cinza de regiões de imagens, entre outras medidas, utilizando a morfologia matemática.

Algumas características principais como área, perímetro, circularidade serão descritas nos tópicos seguintes.

2.5.1.1 Área

Segundo Gonzales (2000), a área de uma região da imagem é definida pelo número de *pixels* contidos dentro de uma fronteira. O cálculo da área é realizado sobre a imagem que tenha passado pelo processo de seleção de área. Este pode ser feito pela contagem de *pixels* de mesma tonalidade. O ideal é utilizar uma imagem binária, onde os *pixels* brancos representam os objetos e os *pixels* pretos o fundo ou vice-versa.

De acordo com Mossmann (2007), o cálculo pode ser feito utilizando a seguinte fórmula:

$$\text{Área} = \frac{\text{área}[\text{pixels}]}{65.935159 \left(\frac{\text{pixels}}{\mu^2} \right)}$$

2.5.1.2 Perímetro

De acordo com Gonzales (2000), o perímetro é o tamanho da fronteira de uma imagem. Seu cálculo é feito a partir da distância entre cada par de *pixels* adjacente que se localizam na borda ou fronteira do objeto.

Após passar o detector de bordas de Canny na imagem e afinar a sua borda, é possível perceber que o perímetro pode ser representado pela borda do objeto.

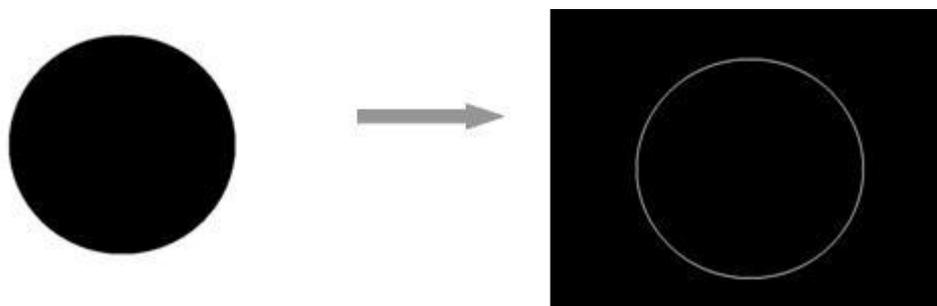


Figura 2.11 - Imagem binarizada e imagem aplicada Canny com afinamento

Para circunferências, pode-se utilizar a seguinte fórmula:

$$\text{Perímetro} = 2 * \pi * \text{raio}$$

Outra forma de calcular o perímetro dos objetos é através da contagem dos *pixels* da borda do objeto de interesse. Normalmente, é utilizada para objetos com formatos indefinidos.

Segundo Parker (1993), para demarcar o perímetro da região de uma imagem binária, são verificados os *pixels* vizinhos do objeto através da diferença de coloração do fundo com a região de interesse da imagem. Assim, quando for encontrada esta diferença, o *pixel* deverá ser marcado com uma nova coloração. A seguir, será mostrado um exemplo utilizando essa técnica.

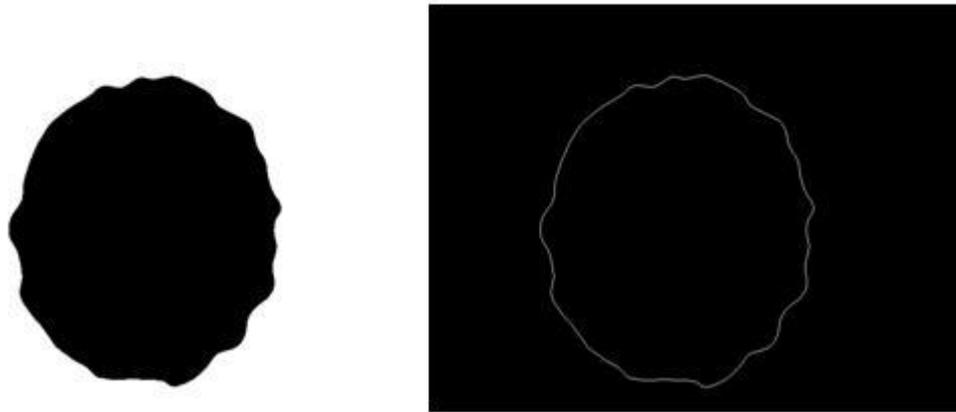


Figura 2.12 - Imagem binária e imagem aplicado o algoritmo de detecção de perímetro

Para verificar o algoritmo de detecção de perímetro, vide o anexo B.

2.5.1.3 Circularidade

A circularidade de um objeto de uma imagem é definida com base na sua área e perímetro. Pode-se dizer que a circularidade é a medida da semelhança de um objeto em relação ao formato de um círculo. Portanto, quanto mais próximo de 1 o valor de circularidade for, mais circular será o objeto, pois o valor de circularidade de um círculo perfeito é igual a 1.

O cálculo pode ser feito utilizando a seguinte fórmula:

$$C = \frac{P^2}{4 \times \pi \times A}$$

Onde C corresponde a circularidade, P é o perímetro e A , a área do objeto.

Existem outras técnicas para extrair informações morfométricas em imagens, porém, neste trabalho será dado ênfase a estas três, pois acredita-se que, com essas técnicas já será possível distinguir entre os tipos de ovos de parasitas estudados.

Após o estudo de algumas formas de análise de imagens da computação gráfica, nota-se que existem técnicas que contribuirão para o desenvolvimento de um *software* para o auxílio ao diagnóstico de exames parasitológicos.

No capítulo seguinte serão abordadas as técnicas que, segundo testes realizados, melhor se adaptam as necessidades do *software* proposto.

3 ANÁLISE DO SISTEMA

O sistema desenvolvido visa auxiliar o diagnóstico de exames parasitológicos de fezes (EPF). Assim, para diminuir a complexidade do desenvolvimento, foram selecionados ovos de dois tipos de parasitas: *Ascaris lumbricoides* e *Trichuris trichiura*. Estes foram escolhidos por serem mais comumente encontrados nestes exames.

A aquisição das imagens é feita através de uma câmera acoplada a um microscópio. A imagem adquirida é encaminhada para o computador, que a processa baseado nas técnicas de análise de imagens estudadas no capítulo anterior.

O *software* faz uma varredura na imagem, buscando regiões de interesse, isto é, procurando objetos que poderão ser ovos. Após encontrados, os objetos são identificados através da sua morfometria, como área, perímetro, circularidade, textura.

3.1 Características do sistema

O *software* foi definido baseado nos conceitos de orientação objeto. Assim, pode-se dizer que um objeto é uma entidade que possui uma identidade, portanto ele é único, mesmo que exista outro objeto com as mesmas características. Os objetos podem ser concretos, como um parasita ou um ovo, ou conceituais, como um serviço de cálculo de área ou circularidade. Suas características e estados são definidos pelos atributos e suas operações são definidas pelos métodos.

Uma classe é uma estrutura que irá derivar em objetos, portanto, todos os objetos são uma instância de uma classe. (MATOS, p.22, 2002; RICARTE, 2001) A figura a seguir apresenta a demonstração de uma classe de dois objetos do sistema.

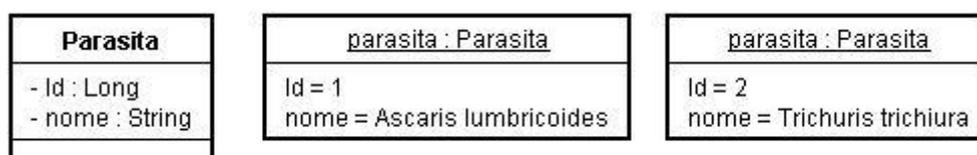


Figura 3.1 - Demonstração de uma classe e dois objetos.

A partir desse contexto, optou-se por desenvolver a análise do *software* baseado no conceito UML.

3.2 Diagramação do software

O processo de análise iniciou-se com o levantamento dos requisitos do *software* a ser desenvolvido. Foram realizadas entrevistas com uma professora e uma aluna do curso de biomedicina do Centro Universitário Feevale, que estão envolvidas na área de parasitologia. A partir desses dados, foram adquiridas as funcionalidades do sistema e seus responsáveis. Neste caso, foram identificados dois atores, o primeiro é o técnico que realiza a análise e o diagnóstico do exame, o outro é o próprio sistema, que possui inúmeras funcionalidades e responsabilidades independentes.

A seguir, é representado o diagrama de Caso de Uso do diagnóstico dos exames parasitológicos de fezes.

Processo de análise de amostra fecal

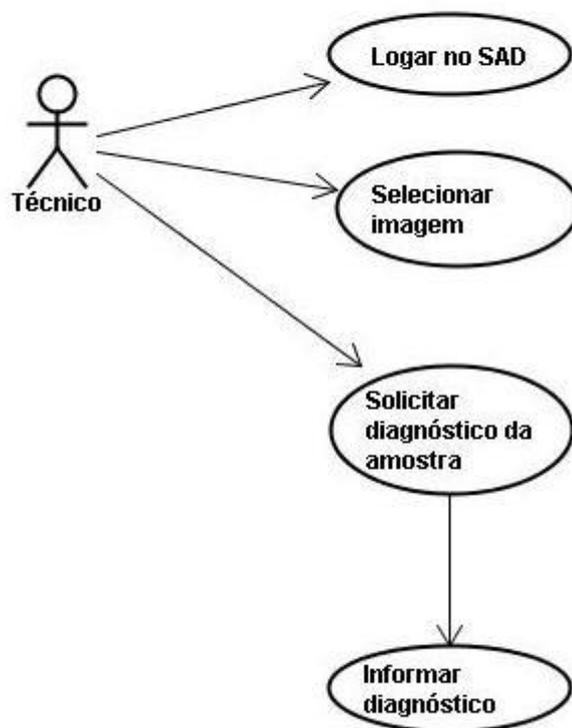


Figura 3.2 - Caso de Uso do processo de análise de amostras fecais

Após a criação do diagrama de Caso de Uso, foram definidas as classes do sistema, que estão sendo representadas no diagrama apresentado a seguir.

Diagrama de classes do Sistema de Apoio ao Diagnóstico em Parasitologia

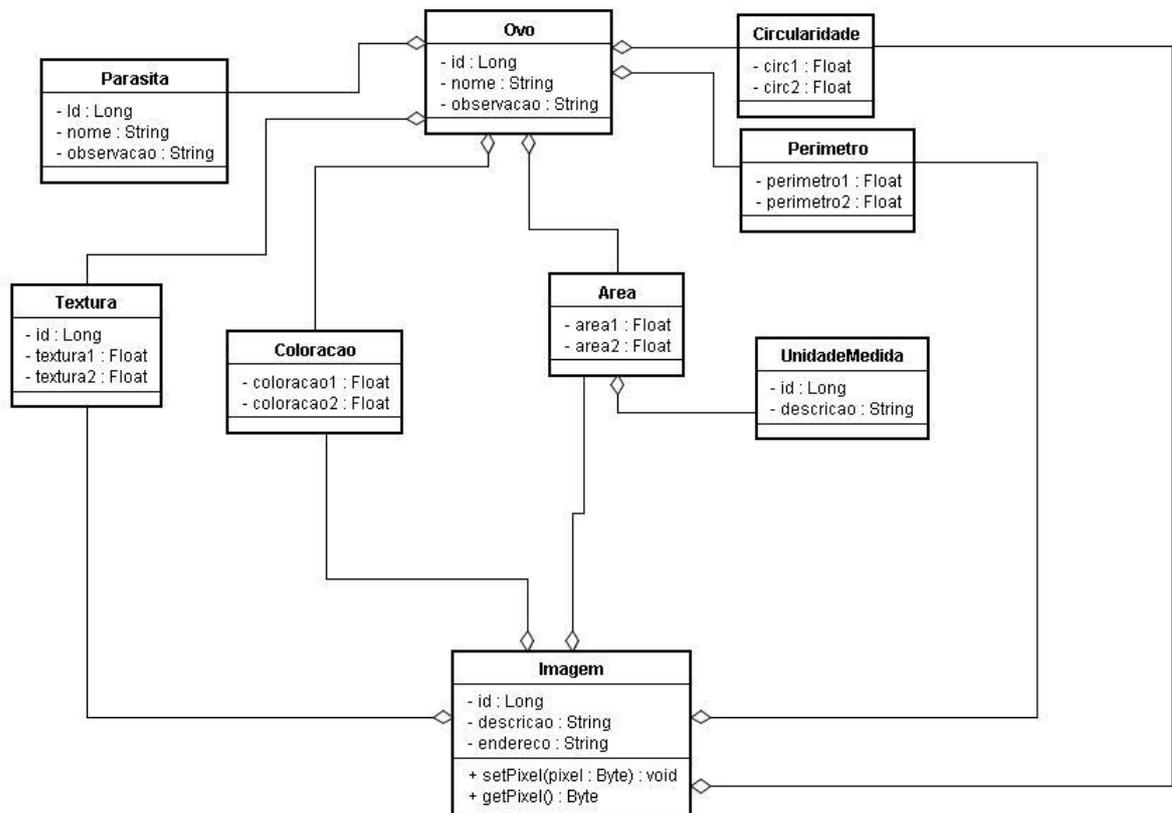


Figura 3.3 - Diagrama de Classes do Software

A partir das classes, existe a necessidade de compreender o comportamento das classes. Portanto, foi gerado, com este intuito, um Diagrama de Atividades.

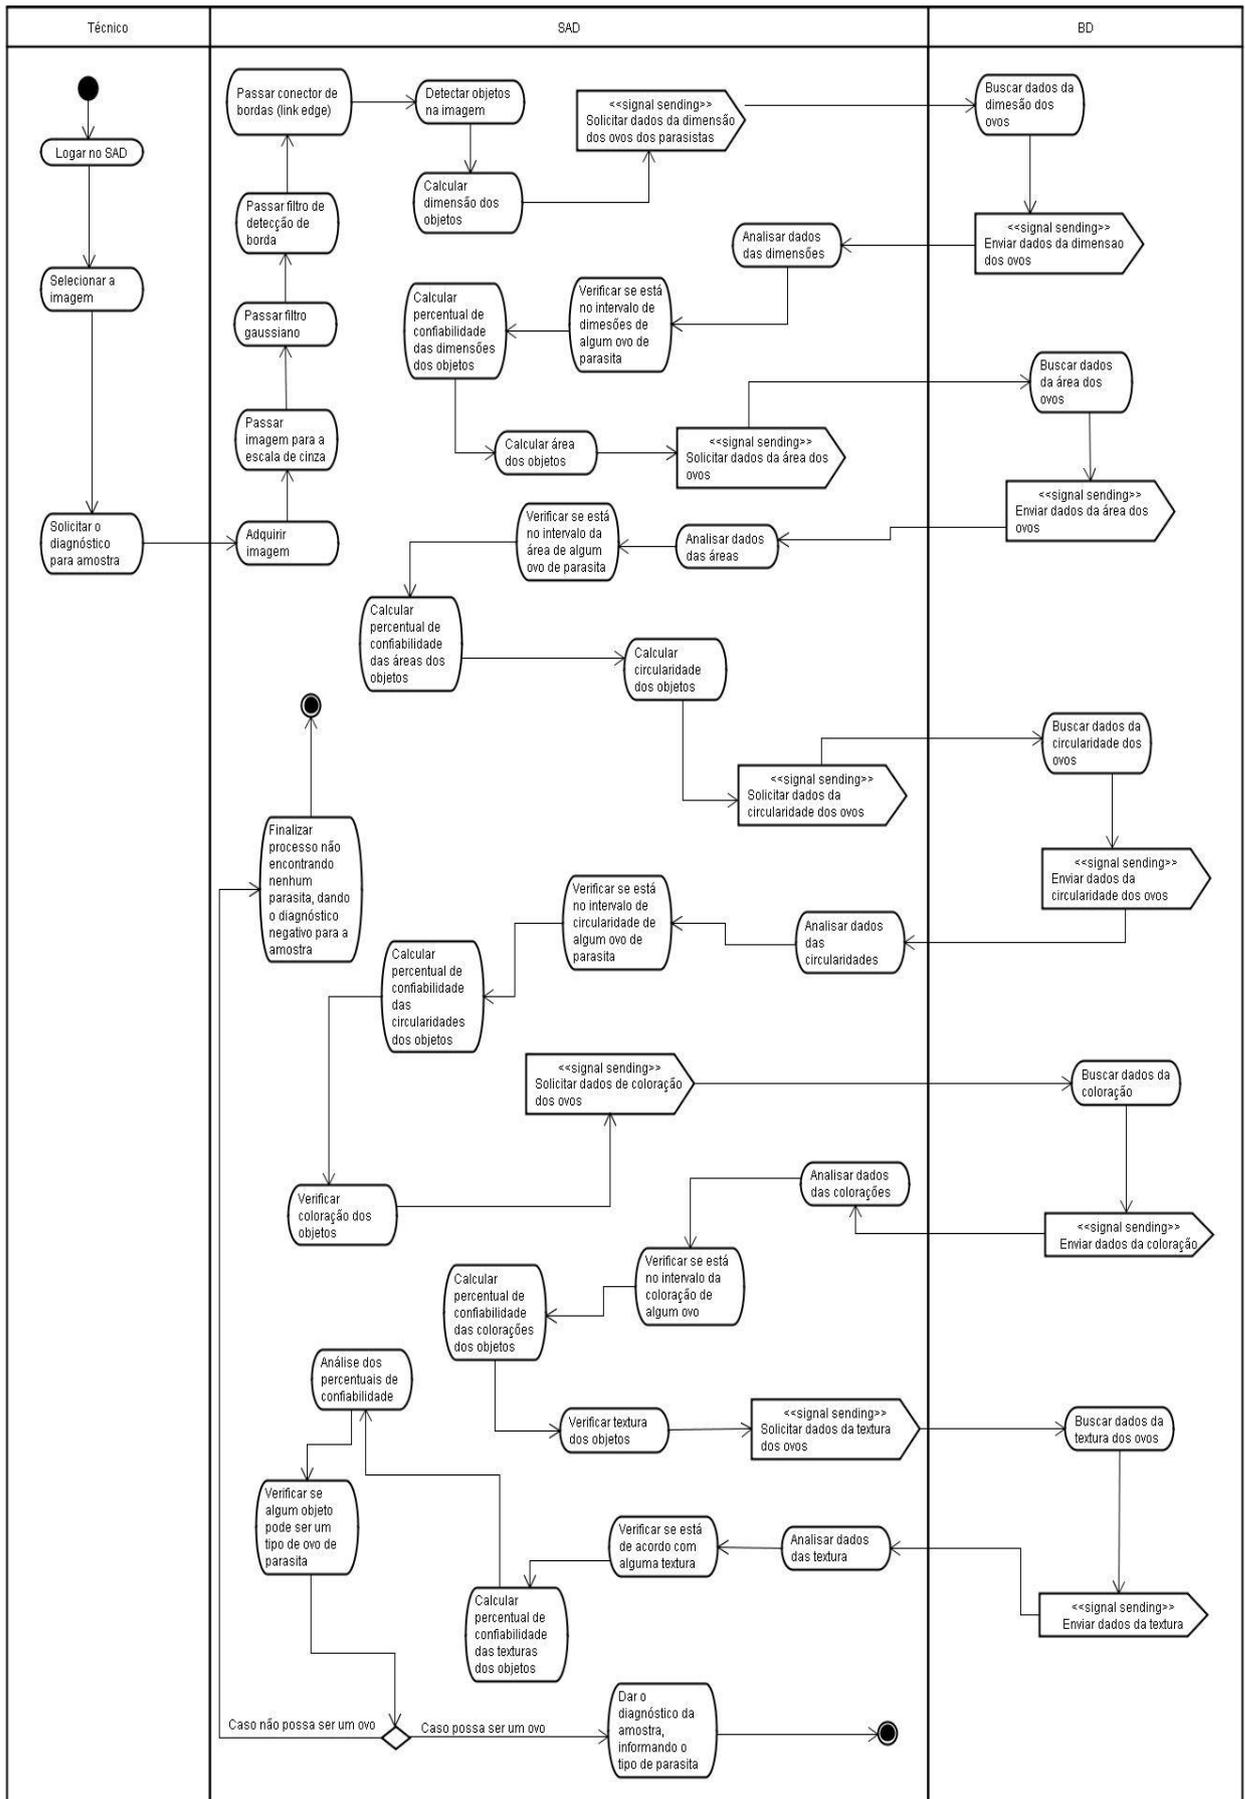


Figura 3.4 - Diagrama de Atividades do software

A análise do sistema foi construída baseada nos dados dos requisitos levantados. No próximo capítulo, será demonstrada toda a construção do protótipo, a implementação dos algoritmos, os problemas identificados e as soluções encontradas em todo processo de desenvolvimento.

4 PROTÓTIPO DO SISTEMA

O desenvolvimento do protótipo do sistema de apoio ao diagnóstico em parasitologia iniciou-se a partir da avaliação dos documentos de análise do software. Com base no referencial teórico, foi realizada a busca de algoritmos que pudessem contribuir com o processo de segmentação e reconhecimento das imagens.

A seguir, serão apresentados todos os passos utilizados para desenvolver o protótipo do sistema.

4.1 Ambiente

No desenvolvimento da ferramenta está sendo utilizado um computador do fabricante Dell, modelo Vostro 1400, com o processador Intel Core 2 Duo, 2 GB de memória RAM, com o sistema operacional Windows Vista do tipo 32 bits.

Para o desenvolvimento é utilizada a linguagem C#, com a plataforma Microsoft Visual Studio 2005 e a ferramenta MATLAB. O C# é uma linguagem de programação orientada a objeto, desenvolvida pela Microsoft. Faz parte da plataforma .NET. e é baseada nas linguagens C++ e Java. (Microsoft, 2008)

De acordo com a Microsoft, o Visual Studio 2005 é um conjunto de ferramentas integradas para o desenvolvimento de *software*. Normalmente, esta plataforma é utilizada para o desenvolvimento em VB.NET e C#.

O MATLAB (MATrix LABoratory) é uma ferramenta que foi concebida originalmente para realizar cálculos com matrizes. Hoje, possui várias facilidades em relação ao processamento de imagens. Segundo Mosmann (2007), é um sistema interativo de fácil manipulação, que permite formular soluções para diversos problemas, principalmente os que envolvem matrizes. Assim, podem-se desenvolver soluções específicas de maneira rápida se comparada às linguagens C ou Fortran. Também possui diversas bibliotecas para atuar em

diferentes áreas da computação científica. Em ambientes universitários, o MATLAB é usado com frequência para pesquisas e desenvolvimento.

4.2 Obtenção das imagens

O projeto está sendo executado em parceria com a professora Rejane Giacomelli Tavares e com a aluna Andressa Priscila Gomes, do curso de Biomedicina. Assim, as imagens foram adquiridas através de uma câmera fotográfica CCD colorida com resolução de (410.000 *pixels*) acoplada ao microscópio Nikon Eclipse E200 e, posteriormente, transferidas para o computador Dell, Intel Pentium III (863 MHz, 256 MB de RAM, 80 GB de disco rígido), formando o banco de imagens.

As imagens são salvas no formato jpeg, com resolução 640 X 480 *pixels*, com um tamanho médio de 250 KB.

O banco de imagens começou a ser obtido em julho de 2008, e as imagens foram armazenadas com a nomenclatura do parasita e um número sequencial para a identificação. Por exemplo, ascaris 1.jpeg, trichuris 10.jpeg, artefato 13.jpeg.

Atualmente, o banco possui 85 imagens de amostras positivas para *Ascaris Lumbricoides* e 54 para *Trichuris Trichiura*. Também conta com 65 imagens de artefatos, isto é, detritos fecais que podem ser confundidos com ovos de parasitas.

4.3 Problemas na segmentação

As primeiras imagens foram adquiridas com baixa resolução e pouco iluminação. Isto ocasionou um excesso de ruído e sujeira. A seguir serão apresentadas algumas destas imagens.



Figura 4.1 - Imagens com excesso de sujeira
Fonte: Laboratório de Bioanálise da Feevale

Na segmentação destas imagens, não foi obtido sucesso, pois a coloração do fundo da imagem estava muito semelhante ao objeto a ser identificado, no caso, ovos de *Ascaris lumbricoides* e *Trichuris trichiura*. Foram passados vários filtros e testados diversos algoritmos que pudessem auxiliar na remoção da sujeira. A seguir, será apresentado o processo de modificação da imagem na busca de melhorias no contraste.

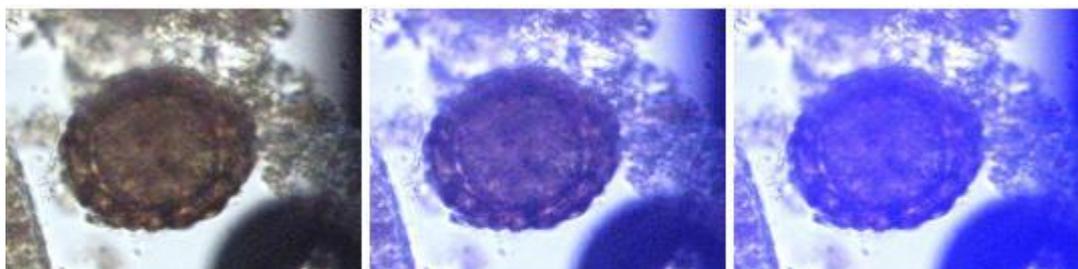


Figura 4.2 - Imagem original, imagem no canal azul e imagem com contraste

Para contornar este problema, as imagens foram adquiridas novamente. Porém, foram aumentadas a resolução e a iluminação na amostra no momento da obtenção da imagem, o que possibilitou uma melhor qualidade na segmentação.

4.4 Melhoria nas imagens obtidas

As imagens passaram por um processo de segmentação, no qual, inicialmente, foi utilizado o filtro gaussiano. Este filtro é utilizado para retirar detalhes irrelevantes da imagem, deixando-a desfocada.

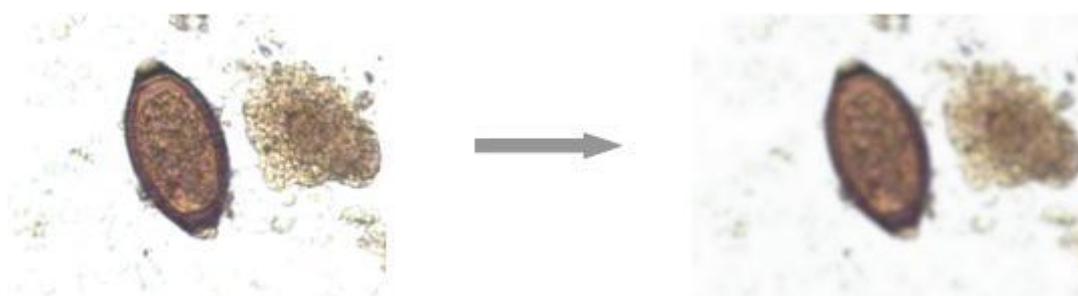


Figura 4.3 - Imagem original e imagem filtrada pelo filtro Gaussiano

Logo após, foi aplicado maior contraste na imagem. Esse mecanismo auxilia no destaque dos objetos da imagem, evidenciando-os.

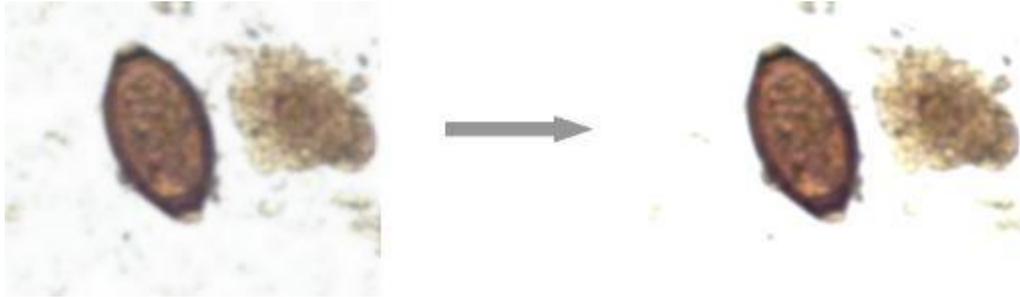


Figura 4.4 - Imagem filtrada pelo filtro Gaussiano e imagem com contraste

Na busca da melhoria da segmentação, foi necessário escolher um canal em que a imagem se adaptasse melhor. Assim, foi implementado um algoritmo para separar a imagem nas suas três bandas (R, G, B).

Analisando as imagens nas bandas, verificou-se que a melhor qualidade na imagem apresentou-se no canal azul. Porém, algumas imagens, ainda apresentavam problemas, pois a coloração do fundo da imagem ficava semelhante a do objeto desejado. Para solucionar esse problema, foi implementado um algoritmo para separar a imagem no canal azul, analisando os *pixels* nos outros canais e dependendo do resultado, alterando o seu valor original. A seguir, um exemplo desse processo.



Figura 4.5 - Imagem com contraste e imagem no canal azul

Ao observar a imagem anterior, verifica-se que existem áreas com colorações diferenciadas, podendo dificultar a binarização. Para deixar a imagem uniforme, foi necessário aplicar novamente o filtro gaussiano.

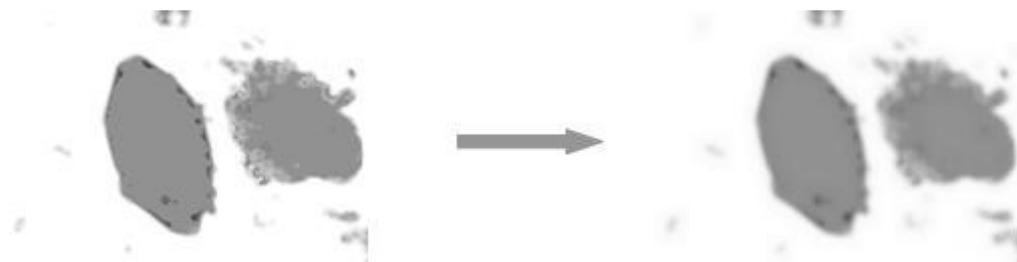


Figura 4.6 - Imagem no canal azul e imagem filtrada com o filtro Gaussiano

Para a obtenção das características dos ovos, como circularidade, área, perímetro, foi necessário binarizar a imagem. Para isso, foi utilizado um limiar onde os *pixels* menores que 165 recebem 0 e os maiores recebem 255. Esses valores foram definidos a partir de testes com a imagem, analisando os limites do fundo e objetos.

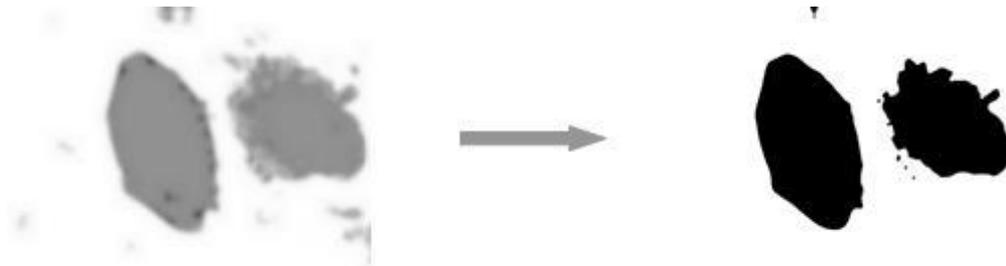


Figura 4.7 - Imagem filtrada com filtro Gaussiano e imagem binária

Após a binarização da imagem, é possível perceber que esta ainda possui uma quantidade elevada de sujeira. Para remover estes resíduos indesejados, foi implementado um algoritmo de *floodfill*. Este foi feito para analisar a área de todos os objetos contidos nas imagens, avaliando qual a área de interesse, isto é, o ovo de *Ascaris lumbricoides* e *Trichuris trichiura*.

Inicialmente, é passado o algoritmo de *floodfill* para detectar os pontos sementes e a área de cada objeto da imagem. Após, é realizada uma análise de todas as áreas encontradas para verificar se estas estão num intervalo possível para ovos de *Ascaris lumbricoides* ou *Trichuris trichiura*. Caso a área seja identificada como um possível ovo de parasita, a imagem é mantida, caso contrário, é passado novamente o algoritmo de *floodfill*, utilizando o ponto semente de cada região, eliminando-as, isto é, pintando as áreas indesejadas com coloração branca.

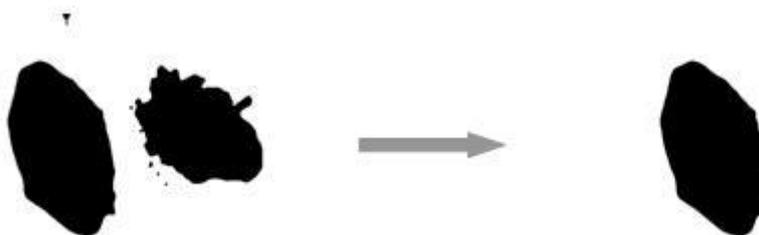


Figura 4.8 - Imagem binarizada e imagem com *floodfill*

Com a imagem binarizada corretamente, foi possível obter as informações relevantes para identificar os ovos, como área, perímetro, circularidade e coloração.

4.5 Identificação dos parasitas

Os ovos dos parasitas *Ascaris lumbricoides* e *Trichuris trichiura* estão sendo identificados através de características da área, perímetro e circularidade dos ovos.

A área está sendo definida pelo número de *pixels* de coloração preta da imagem binarizada. Após, para obter a medida do perímetro é aplicado um detector de bordas na imagem, assim, é identificada a quantidade de *pixels* da borda. Com a área e perímetro, é aplicado o cálculo da circularidade demonstrado no capítulo 2.

A partir de vários testes com amostras positivas, foi definido que a área dos ovos de *Ascaris lumbricoides* está num intervalo de 60.000 a 100.000 *pixels*. Já a de *Trichuris trichiura* está num intervalo de 20.000 a 41.000. Também foi definido que os ovos de *Ascaris lumbricoides* possuem circularidade entre de 0.79 a 1.1 e os de *Trichuris trichiura* possuem circularidade entre 0.9 e 1.2.

Tabela 4.1 - Intervalo dos valores de área, perímetro e circularidade de cada parasita

	<i>Ascaris lumbricoides</i>	<i>Trichuris trichiura</i>
Área	60.000 - 100.000	20.000 - 41.000
Perímetro	800 - 1095	591 - 791
Circularidade	0.79 - 1.1	0.9 - 1.2

Após os valores de área, perímetro e circularidade calculados, é feito um comparativo verificando se os valores encontrados estão num intervalo possível de área e circularidade dos ovos *Trichuris trichiura*. Caso não estejam, é feito o mesmo comparativo para os ovos de *Ascaris lumbricoides*.

Assim, baseado nessas conclusões é possível fazer o reconhecimento dos ovos de parasitas, identificando se a amostra é positiva para *Ascaris lumbricoides* ou *Trichuris trichiura*.

4.6 Utilização do protótipo

O protótipo foi disponibilizado para testes ao grupo de Bioanálise do Centro Universitário Feevale. A seguir será apresentada a tela principal do software.

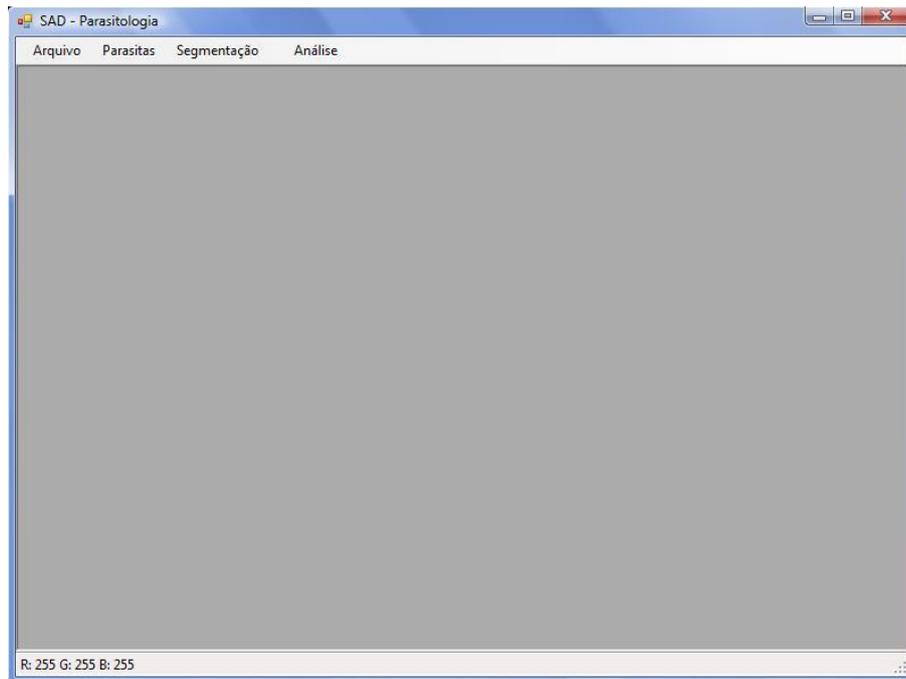


Figura 4.9 - Tela principal do protótipo

O diagnóstico deve ser iniciado utilizando o menu, na opção Arquivo. O usuário deverá selecionar a opção Abrir e selecionar a imagem.

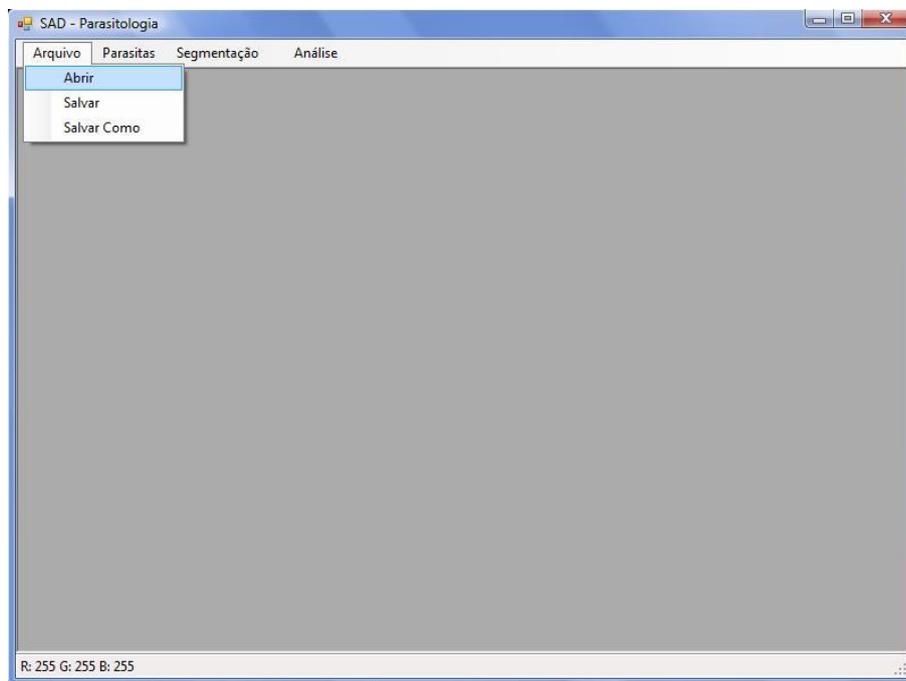


Figura 4.10 - Demonstração da abertura da imagem

Após a abertura da imagem, o usuário poderá selecionar a opção Parasitas e, logo após, a opção Diagnóstico. Para obter o diagnóstico dado pelo software, o usuário deverá aguardar de 5 a 10 segundos. Estes valores podem ser alterados por diferenças de hardware,

como capacidade do processador, memória, ou até mesmo software, como sistema operacional e processos em execução na máquina que está sendo utilizado o protótipo.



Figura 4.11 - Início do diagnóstico

Após a formulação do diagnóstico, este deverá ser apresentado da seguinte forma:



Figura 4.12 - Diagnóstico positivo para *Ascaris lumbricoides*

Da mesma forma, o software pode ser utilizado para ovos de *Trichuris trichiura*.

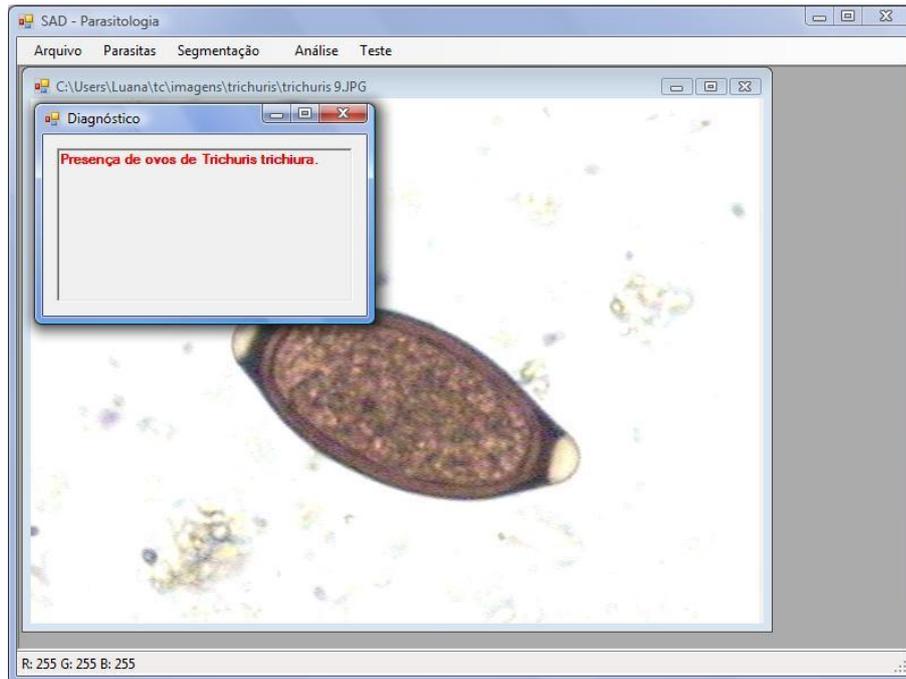


Figura 4.13 - Diagnóstico positivo para *Trichuris trichiura*

Caso a amostra não apresente ovos de parasitas de *Ascaris lumbricoides* e *Trichuris trichiura*, o software deverá se comportar da seguinte forma:

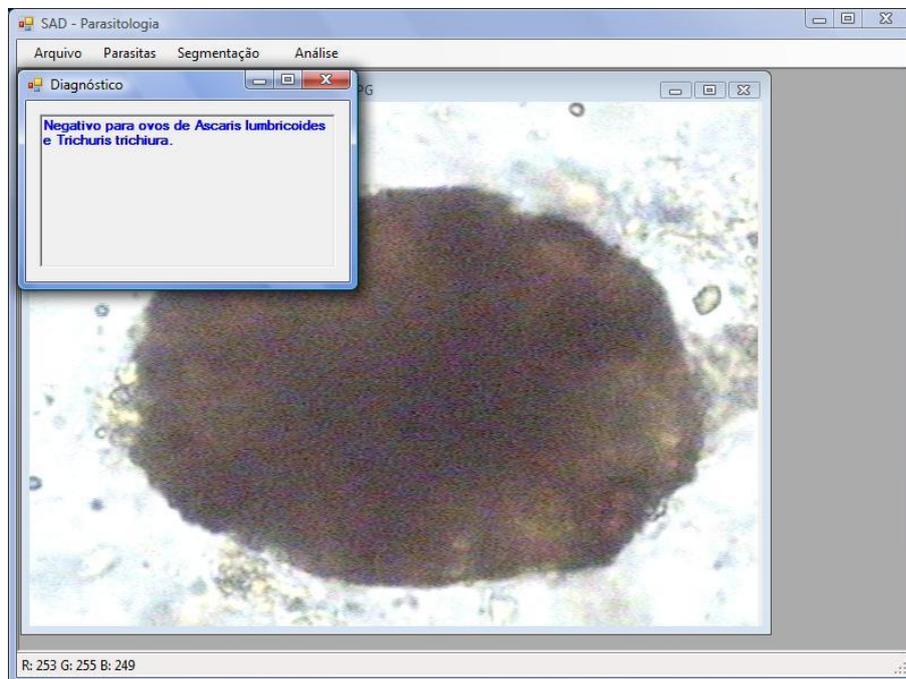


Figura 4.14 - Diagnóstico negativo para *Ascaris lumbricoides* e *Trichuris trichiura*

Após a demonstração do software, serão apresentados os resultados obtidos ao longo do processo de teste.

4.7 Resultados

Para os testes do sistema, foram obtidas 54 imagens de *Trichuris trichiura*, 85 imagens de *Ascaris lumbricoides* e 65 imagens de artefatos, totalizando 204 imagens. Estas imagens foram selecionadas buscando atingir uma grande gama de variações possíveis de serem encontradas em lâminas de EPFs. Ao analisar as imagens, é possível perceber algumas imagens nítidas e com boa iluminação e imagens ruins, ou seja, escuras, imagens deformadas e com bastante sujeira, o que prejudica a análise pelo software.

A tabela a seguir apresenta os tipos de laminas analisadas, com seus respectivos percentuais de erro e acerto.

Tabela 4.2 - Resultados totais

TIPO	Total	Erro	% Erro	% Acerto
<i>Trichuris trichiura</i>	54	17	31,4815	68,5185
<i>Ascaris lumbricoides</i>	85	15	17,6471	82,3529
Artefatos	65	6	9,2308	90,7692
TOTAL	204	38	18,6275	81,8627

A seguir serão analisados os principais casos que apresentaram problemas na identificação quando na imagem existem somente artefatos, sem apresentar ovos de parasitas.

Tabela 4.3 - Resultados problemáticos de amostras de artefatos

Art.	Imagem	Área	Perímetro	Circularidade	Observação
31		36.198	687	1,04	Positivo para <i>Trichuris trichiura</i>
41		78.047	993	1,01	Positivo para <i>Ascaris lumbricoides</i>
43		92.969	1.089	1,02	Positivo para <i>Ascaris lumbricoides</i>
46		99.065	1.027	0,84	Positivo para <i>Ascaris lumbricoides</i>
51		90.635	1.007	0,89	Positivo para <i>Ascaris lumbricoides</i>
62		35.968	669	0,99	Positivo para <i>Trichuris trichiura</i>

Neste caso, as imagens encontradas de artefatos se assemelharam a imagens de ovos de *Trichuris trichiura* ou de *Ascaris lumbricoides*, como pode ser observado nas imagens da tabela anterior. Das 65 imagens de artefatos, apenas 6 apresentaram problemas, ou seja, obteve-se 90,77% de acerto ao encontrar a informação desejada.

A seguir, serão apresentadas algumas amostras que apresentaram problemas na identificação dos ovos de *Trichuris trichiura*.

Tabela 4.4 - Resultados problemáticos de amostras de *Trichuris trichiura*

Trichuris	Original	Segment.	Resultado	Área	Perím.	Circ.	Obs
2			Negativo	66678	1837	4,03	O excesso de sujeira na lâmina.
5			Negativo	69195	891	0,91	O excesso de sujeira na lâmina.
6			Negativo	37226	338	0,24	A sujeira encontrada prevaleceu ao ovo de parasita.
11			Negativo	33508	793	1,49	A sujeira prejudicou a segmentação da imagem.
16			Negativo	38172	760	1,02	Sujeira forte grudada no ovo.
17			Negativo	***	***	***	O excesso de sujeira na lâmina. Esta ficou cinza por problema com o <i> floodfill</i> .

Ao analisar os resultados, verifica-se que das 54 amostras positivas para *Trichuris trichiura*, 17 imagens obtiveram problemas, gerando um percentual de acertos de 68,52%. Os problemas de identificação dos ovos ocorreram pelo excesso de resíduos fecais contidos na imagem, principalmente, a sujeira encostada no objeto de interesse, prejudicando a segmentação.

Para verificar todos os resultados obtidos nas 54 amostras de *Trichuris trichiura*, vide o anexo C.

A seguir, serão apresentadas algumas amostras positivas de *Ascaris lumbricoides* que apresentaram problemas.

Tabela 4.5 - Resultados problemáticos de amostras de *Ascaris lumbricoides*

Ascaris	Original	Segment.	Resultado	Área	Perím.	Circ.	Obs
7			Negativo	79454	1089	1,19	O excesso de luminosidade na lâmina.
9			Negativo	79546	1600	2,56	O excesso de luminosidade na lâmina.
44			Negativo	80722	1176	1,36	O excesso de sujeira na lâmina.
63			Negativo	62566	1567	3,12	A coloração do objeto muito semelhante a coloração do fundo da amostra.
64			Negativo	97250	1238	1,25	O excesso de sujeira na lâmina.
79			Negativo	34571	1286	3,80	A coloração do objeto muito semelhante a coloração do fundo da amostra.

Nos testes das 85 amostras positivas de *Ascaris lumbricoides*, 14 apresentaram problemas no diagnóstico, gerando um percentual de acerto de 83,53%. A maioria dos erros ocorreu por falha na segmentação da imagem, decorrentes do excesso de sujeira na amostra ou do excesso de luminosidade, causando buracos dentro do ovo.

Para verificar todos os resultados das 85 amostras de *Ascaris lumbricoides* vide o anexo D.

O percentual total de acertos geral do sistema foi 81,86%. Para um sistema inicial, sem similar encontrado, pode ser considerado bastante elevado e aceito para um sistema de apoio ao diagnóstico, onde o mesmo apresenta a sugestão ao parasitologista e o resultado final depende da opinião do mesmo.

CONCLUSÃO

Após a observação da forma como são elaborados os diagnósticos dos exames parasitológicos de fezes, verifica-se a possibilidade de automatização nessa área. Também é possível perceber que o uso de computadores na área da saúde tem se desenvolvido bastante, e é através da computação gráfica que a maioria dos *softwares* médicos estão sendo desenvolvidos.

O sistema baseia-se na informatização da análise das imagens médicas, buscando extrair detalhes que, em alguns casos, o ser humano não consegue perceber, e também analisá-los. Porém, isto não significa que os profissionais da área médica não precisarão participar do diagnóstico. Na verdade, eles deverão verificar o resultado gerado pelo sistema auxiliar, criando um diagnóstico com maior precisão e de forma mais simplificada.

A equipe desenvolvedora deste sistema conta com a participação de uma aluna do curso de Biomedicina e uma professora da disciplina de Parasitologia do Centro Universitário Feevale. Assim, verifica-se que a parceria entre diferentes áreas do conhecimento faz-se presente como um dos pontos a ser destacado no trabalho desenvolvido.

No início do projeto, foram feitas pesquisas sobre parasitologia, enfatizando nas formas de diagnosticar amostras fecais. Desta forma, foram verificados os principais parasitas encontrados nas amostras fecais, dentre estes, selecionados dois tipos de parasitas para serem estudados: *Ascaris lumbricoides* e *Trichuris trichiura*. Estes parasitas são detectados, normalmente, pelos seus ovos e, por isso, foram escolhidos por terem ovos com formatos bastante diferenciados.

Após, as pesquisas foram enfocadas no formato e na coloração dos ovos, com o objetivo de encontrar formas de identificar o parasita na amostra.

Logo, foram iniciadas pesquisas referentes à computação gráfica, buscando formas de processamento de imagens para remover a sujeira, focando apenas no objeto de interesse, no caso, o ovo do parasita, para extrair as suas características morfométricas.

A análise do sistema foi construída baseada nas informações adquiridas através das entrevistas com profissionais da área biomédica e das pesquisas sobre parasitologia. De acordo com a modelagem, foi realizado o desenvolvimento do sistema.

O objetivo inicial do software era auxiliar o diagnóstico de amostras parasitológicas. Após algumas sugestões de profissionais da área biomédica, pretende-se utilizar o software também para o auxílio a estudantes da área biomédica.

Com base nas 204 imagens adquiridas, obteve-se um percentual de acerto de 81,86%, o que indica que foi obtido sucesso no protótipo desenvolvido. Para um sistema inicial, sem nenhum similar encontrado, a taxa é bastante alta. Porém, ainda existem alguns problemas na segmentação de algumas imagens, principalmente nas amostras de *Trichuris trichiura*. Isto ocorre, principalmente, pelo excesso de resíduos fecais contidos nas amostras.

Para trabalhos futuros, propõe-se melhorar o desenvolvimento de alguns algoritmos, como o de *floodfill*, que para algumas imagens apresenta erro na segmentação. Também pretende-se implementar PCA (Análise de Componentes Principais) para melhorar o percentual de acertos no reconhecimento dos ovos do parasitas.

Segundo pesquisas da Unicamp, mencionadas na página 18 deste trabalho, o percentual de acertos dos diagnósticos atuais de parasitologia variam de 48% a 76%. O protótipo desenvolvido apresentou um percentual de acertos de 81,86%, isto é, 5,86% mais alto do que os exames convencionais, levando a crer que a continuidade deste projeto tem um valor significativo na automação e no melhoramento dos exames parasitológicos de fezes.

No ano de 2009 pretende-se implementar o diagnóstico para novos tipo de parasitas. Para o reconhecimento, verifica-se a possibilidade de implementar redes bayesianas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES FILHO, Manuel. 'Olho eletrônico' obtém detecção automática de parasitos intestinais. **Jornal da Unicamp**, Universidade Estadual de Campinas - SP, 361. ed. p. 5, 11-17 Jun. 2007. Disponível em: <http://www.unicamp.br/unicamp/unicamp_hoje/ju/junho2007/ju361pag05.html>. Acesso em: 08 de maio de 2008.
- BASTOS. **Segmentação**. UFPEL - Brasil, 2000. Disponível em: <<http://atlas.ucpel.tche.br/~vbastos/segmenta.htm#10>>. Acesso em: 08 de maio de 2008.
- BUENO, Marcelo L. **Detecção de Bordas através de Algoritmo Canny**. UFSC – Brasil, 2000. Disponível em: <<http://www.inf.ufsc.br/~visao/2000/Bordas/index.html>>. Acesso em: 04 de maio de 2008.
- CARDOSO, Jiane. **Sistemas de Apoio à Decisão**. PUCRS – Brasil, 2005. Disponível em: <<http://www.pucrs.campus2.br/~jiani/si/sad-parte1.ppt>>. Acesso em: 19 de abril de 2008.
- CIMERMAN, Benjamin; CIMERMAN, Sérgio. **Parasitologia Humana e seus Fundamentos Gerais**. 2. ed. São Paulo: Atheneu, 2001. 390 p.
- CONCI, Aura; AZEVEDO, Eduardo; LETA, Fabiana R. **Computação Gráfica**. 1. ed. Rio de Janeiro: Elsevier, 2008.
- DE CARLI, Geraldo Attilio. Parasitologia clínica: seleção de métodos e técnicas de laboratório para o diagnóstico das parasitoses humanas. São Paulo: Atheneu, 2001. 810 p.
- FALSARELLA, Orandi M; CHAVES, Eduardo O. C. **Sistemas de Informação e Sistemas de Apoio à Decisão**. Brasil, 2004. Disponível em: <<http://www.chaves.com.br/TEXTSELF/COMPUT/sad.htm>>. Acesso em: 19 de abril de 2008.
- GATTASS, Marcelo. **Imagem Digital**. PUC – Brasil, 2005. Disponível em: <www.tecgraf.puc-rio.br/~mgattass/cg/pdf/03_ImagemDigital.pdf>. Acesso em: 20 de maio de 2008.
- GOMES, T.C.; ALMEIDA, M.F.; MIURA, L.A. *et al.* **Helmintoses intestinais em população de rua da cidade do Rio de Janeiro**. Rev. Soc. Bras. Med. Trop. Uberaba, vol.35, n.5, p.531-532, Set./Out. 2002.
- GONZALEZ, C.Rafael; WOODS, E.Richard. **Processamento de Imagens Digitais**. 1 ed, São Paulo: Blucher, 2000.
- GONZALEZ, C.Rafael; WOODS, E.Richard; EDDINS, Steven L. **Digital Image Processing using Matlab**. 1 ed, Nova Jersey, Estados Unidos: Pearson Prentice Hall, 2004.
- GUILHERME, L. R.W. **Uma abordagem de afinamento por aprendizagem através de exemplos**. PUCPR – Brasil, 2007. Disponível em:

<<http://www.ppgia.pucpr.br/teses/DissertacaoPPGIa-LuisRenato-2007.pdf>>. Acesso em: 10 de maio de 2008.

HORNINK, Gabriel G. **Guia de estudo de ciclo de vida de parasitas e seus danos ao hospedeiro, através da simulação de exame parasitológico de fezes**. Brasil, 2008. Disponível em: <http://www.e-science.unicamp.br/lteib/admin/projetos/documentos/textocompleto_643_relatorio%20final%20Gab.pdf>. Acesso em: 20 de maio de 2008.

JÚNIOR, Sérgio A. M. B. **Sistemas de Apoio à Decisão**. Urcamp – Brasil, 2006. Disponível em: <<http://www.al.urbcamp.tche.br/infocamp/edicoes/nov05/Apoio%20a%20Decisao.pdf>>. Acesso em: 20 de maio de 2008.

LOPES, Eduardo C. **Determinando a Posição e a Orientação da Mão Através de Imagens de Vídeo**. PUCRS – Brasil, 2005. Disponível em: <<http://grv.inf.pucrs.br/projects/hts/LOPES,%20Eduardo%20Costa.pdf>>. Acesso em: 10 de outubro de 2008.

MARTINO, J. Mario de. **Técnicas de Realce da Imagem**. Unicamp - Brasil. Disponível em: <<http://www.dca.fee.unicamp.br/~martino/disciplinas/ea978/na9.pdf>>. Acesso em: 05 de maio de 2008.

MATOS, Alexandre V de. **UML: Prático e Descomplicado**. São Paulo: Érica, 2. ed. 2002.

MICROSOFT. **Visual C#**. Brasil, 2008. Disponível em: <<http://www.microsoft.com/brasil/msdn/csharp/Default.aspx>>. Acesso em: 07 de junho de 2008.

MORAES, Denis A. De O. **Algoritmo para suavização de imagens digitais por filtragem Gaussiana em connection machine**. UFRGS – Brasil, 2006. Disponível em: <www.inf.ufrgs.br/procpar/disc/cmp135/trabs/daltieri/AlgoritmoGaussianFilteringCM_DenisAltieri.doc>. Acesso em: 16 de maio de 2008.

MOSSMANN, João B. **Estudo de técnicas de processamento de imagens aplicadas ao apoio do diagnóstico de derrames serosos de etiologia benigna e maligna**. Feevale – Brasil, 2007. Disponível em: <<http://ead.feevale.br/tc/index.php?codcurso=1>>. Acesso em: 01 de maio de 2008.

NEVES, David Pereira. **Parasitologia dinâmica**. 2. ed. São Paulo: Atheneu, 2006. 495 p.

PARKER, J. R. **Practical computer vision using C**. USA: Wiley, 1993.

PEDRINI, Hélio; SCHWARTZ, W. Robson. **Análise de imagens digitais: princípios, algoritmos e aplicações**. 1. ed, São Paulo: Thomson Learning, 2008.

PINTO, Bruno F; REINBRECHT, César R.W. **Aplicação de Visão Computacional em Linguagem de Programação C#**. PUCRS – Brasil, 2007. Disponível em: <http://www.inf.pucrs.br/~petinf/homePage/publicacoes/documentos/relatorios%20tecnico/cesar.reinbrecht_2007.pdf>. Acesso em: 08 de maio de 2008.

REY, Luís. **Bases da Parasitologia Médica**. 2. ed. Rio de Janeiro: Guanabara Koogan, 2002. 379 p.

RICARTE, Ivan L. M. **Introdução a Orientação a Objetos**. Unicamp – Brasil, 2001. Disponível em: <http://www.dca.fee.unicamp.br/cursos/POO_CPP/node3.html>. Acesso em: 07 de junho de 2008.

SHAPIRO, Linda; STOCKMAMN, George. **Computer Vision**. Estados Unidos, 2000.

SILVA, Cleudeni G. da.; SANTOS, Hudson A. dos. **Ocorrência de parasitoses intestinais da área de abrangência do Centro de Saúde Cícero Idelfonso de Regional Oeste da Prefeitura Municipal de Belo Horizonte, Minas Gerais. Revista de Biologia e Ciência da Terra** – Brasil, 2001. Disponível em: <<http://www.uepb.edu.br/eduep/rbct/sumarios/pdf/parasitoses.pdf>>. Acesso em: 27 de fev. de 2008.

TAVARES, Rejane G. Entrevista com a pesquisadora em parasitologia. 04 de mar. de 2008.

Endolimax nana. UFMG – Brasil, 2008. Disponível em: <<http://www.farmacia.ufmg.br/ACT/atlas/endolimaxnana.htm>>. Acesso em: 18 de jun. de 2008.

Entamoeba coli. UFRGS – Brasil, 2008. Disponível em: <<http://www.ufrgs.br/parasite/Imagensatlas/Protozoa/Entamoebacoli.htm>>. Acesso em: 18 de jun. de 2008.

Giardia lamblia. UFRGS – Brasil, 2008. Disponível em: <<http://www.ufrgs.br/parasite/Imagensatlas/Protozoa/Giardialambli.htm>>. Acesso em: 18 de jun. de 2008.

ANEXO A

A seguir será mostrado o algoritmo *floodfill*.

```
public void buscaRegiao(int x, int y, ImageData imageData, int valorOld, int
valorNew)
{
    if (imageData.GetPixelDestino(x, y) == valorOld)
    {
        count++;
        imageData.SetPixel(x, y, Convert.ToByte(valorNew));

        if (y > 0)
        {
            if (imageData.GetPixelDestino(x, y - 1) == valorOld)
                this.buscaRegiao(x, y - 1, imageData, valorOld,
valorNew);
        }

        if (x < imageData.Width - 1)
        {
            if (imageData.GetPixelDestino(x + 1, y) == valorOld)
                this.buscaRegiao(x + 1, y, imageData, valorOld,
valorNew);
        }

        if (x > 0)
        {
            if (imageData.GetPixelDestino(x - 1, y) == valorOld)
                this.buscaRegiao(x - 1, y, imageData, valorOld,
valorNew);
        }

        if (y < imageData.Height - 1)
        {
            if (imageData.GetPixelDestino(x, y + 1) == valorOld)
                this.buscaRegiao(x, y + 1, imageData, valorOld,
valorNew);
        }
    }
}
```

ANEXO B

A seguir será mostrado o algoritmo desenvolvido para detectar os perímetros de objetos em imagens binárias.

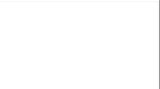
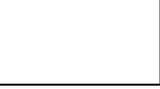
```
int marker = 100;

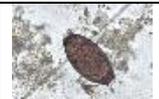
for (int x = 1; x < imageData.Width - 1; x++)
{
    for (int y = 1; y < imageData.Height - 1; y++)
    {
        if (imageData.GetPixel(x, y) == colorNew)
        {
            if (imageData.GetPixel(x + 1, y) == 255 &&
imageData.GetPixel(x + 1, y) != marker)
            {
                imageData.SetPixel(x + 1, y, Convert.ToByte(marker));
            }
            if (imageData.GetPixel(x, y + 1) == 255 &&
imageData.GetPixel(x, y + 1) != marker)
            {
                imageData.SetPixel(x, y + 1, Convert.ToByte(marker));
            }
            if (imageData.GetPixel(x - 1, y) == 255 &&
imageData.GetPixel(x - 1, y) != marker)
            {
                imageData.SetPixel(x - 1, y, Convert.ToByte(marker));
            }
            if (imageData.GetPixel(x, y - 1) == 255 &&
imageData.GetPixel(x, y - 1) != marker)
            {
                imageData.SetPixel(x, y - 1, Convert.ToByte(marker));
            }
        }
    }
}
```

ANEXO C

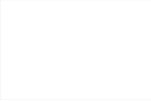
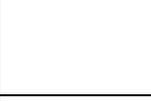
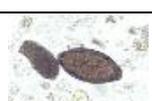
Análise dos dados de *Trichuris trichura*, contendo informações de área, perímetro, circularidade e justificativas.

Tabela 5.1 - Resultados das amostras de *Trichuris trichiura*

Trichuris	Original	Segment.	Resultado	Área	Perím.	Circ.	Observação
1			Positivo	29342	591	0,95	
2			Negativo	66678	1837	4,03	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
3			Positivo	34134	661	1,02	
4			Positivo	32681	637	0,99	
5			Negativo	69195	891	0,91	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
6			Negativo	37226	338	0,24	A sujeira encontrada prevaleceu ao ovo de parasita.
7			Positivo	34154	639	0,95	
8			Positivo	32716	663	1,07	
9			Positivo	32180	639	1,01	
10			Positivo	35087	653	0,97	

11			Negativo	33508	793	1,49	A sujeira prejudicou a segmentação da imagem.
12			Positivo	37260	685	1,00	
13			Negativo	***	***	***	
14			Positivo	34642	667	1,02	
15			Positivo	37946	718	1,08	
16			Negativo	38172	760	1,02	Sujeira forte grudada
17			Negativo	***	***	***	O excesso de sujeira na lâmina prejudicou a segmentação da imagem. Esta ficou cinza por problema com o <i>floodfill</i> .
18			Positivo	40484	721	1,02	
19			Negativo	36135	711	1,11	A sujeira prejudicou a segmentação da imagem.
20			Positivo	34792	678	1,05	
21			Negativo	39367	365	0,27	Pegou como maior área a sujeira.
22			Positivo	34539	659	1,00	
23			Positivo	35387	676	1,03	
24			Positivo	34236	678	1,07	
25			Negativo	34348	701	1,14	A sujeira prejudicou a segmentação da imagem.
26			Positivo	32064	635	1,00	

27			Positivo	34520	656	0,99	
28			Positivo	31994	791	1,56	
29			Positivo	34539	658	1,00	
30			Positivo	35238	658	0,98	
31			Positivo	34330	661	1,01	
32			Positivo	34506	655	0,99	
33			Positivo	32473	622	0,95	
34			Positivo	34208	650	0,98	
35			Positivo	33355	648	1,00	
36			Positivo	31532	648	1,06	
37			Positivo	33481	637	0,96	
38			Positivo	30467	658	1,13	
39			Negativo	40845	1278	3,18	O excesso de sujeira e luminosidade na lâmina prejudicou a segmentação da imagem.
40			Positivo	34349	669	1,04	
41			Positivo	34503	665	1,02	
42			Negativo	36021	735	1,19	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
43			Positivo	32378	656	1,06	

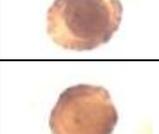
44			Positivo	33250	646	1,00	
45			Negativo	38388	337	0,24	Pegou como maior área a sujeira.
46			Negativo	33928	842	1,66	
47			Positivo	33833	695	1,14	
48			Positivo	35331	717	1,16	
49			Positivo	33746	670	1,06	
50			Positivo	35631	689	1,06	
51			Positivo	30861	619	0,99	
52			Negativo	34385	960	2,13	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
53			Negativo	39740	837	1,40	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
54			Negativo	***	***	***	O excesso de sujeira na lâmina prejudicou a segmentação da imagem. Esta ficou cinza por problema com o <i>loodfill</i> .

ANEXO D

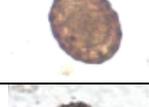
Análise dos dados de *Ascaris Lumbricoides*, contendo informações de área, perímetro, circularidade e justificativas.

Tabela 5.2 - Resultados das amostras de *Ascaris lumbricoides*

Ascaris	Original	Segment.	Resultado	Área	Perím.	Circ.	Observação
1			Positivo	84961	951	0,85	
2			Positivo	70192	858	0,83	
3			Positivo	80762	931	0,85	
4			Positivo	84960	949	0,84	
5			Positivo	88591	983	0,85	
6			Positivo	84096	948	0,85	
7			Negativo	79454	1089	1,19	O excesso de luminosidade na lâmina prejudicou a segmentação da imagem.
8			Negativo	***	***	***	O excesso de luminosidade na lâmina prejudicou a segmentação da imagem.
9			Negativo	79546	1600	2,56	O excesso de luminosidade na lâmina prejudicou a segmentação da imagem.

10			Negativo	***	***	***	O excesso de luminosidade na lâmina prejudicou a segmentação da imagem.
11			Positivo	71849	864	0,83	
12			Positivo	82133	997	0,96	
13			Positivo	82435	968	0,90	
14			Positivo	75497	899	0,85	
15			Positivo	87431	999	0,91	
16			Positivo	69535	854	0,83	
17			Positivo	83941	955	0,86	
18			Positivo	76468	914	0,87	
19			Positivo	80156	927	0,85	
20			Positivo	69241	845	0,82	
21			Positivo	73233	895	0,87	
22			Positivo	77569	932	0,89	
23			Positivo	75654	905	0,86	
24			Positivo	69645	848	0,82	
25			Positivo	77930	900	0,83	
26			Positivo	75200	891	0,84	

27			Positivo	60936	800	0,83	
28			Positivo	77015	927	0,89	
29			Positivo	81725	946	0,87	
30			Positivo	72929	886	0,86	
31			Positivo	78678	924	0,86	
32			Positivo	66101	838	0,85	
33			Positivo	74189	894	0,86	
34			Positivo	71342	917	0,94	
35			Positivo	75308	888	0,83	
36			Positivo	68649	845	0,83	
37			Negativo	74479	1246	1,66	O excesso de luminosidade na lâmina prejudicou a segmentação da imagem.
38			Positivo	95851	1050	0,91	
39			Positivo	73903	879	0,83	
40			Positivo	92905	999	0,85	
41			Positivo	88705	966	0,84	
42			Positivo	98710	1034	0,86	
43			Positivo	88228	999	0,90	

44			Negativo	80722	1176	1,36	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
45			Positivo	75583	916	0,88	
46			Positivo	81434	931	0,85	
47			Positivo	89783	981	0,85	
48			Positivo	82919	996	0,95	
49			Positivo	83136	982	0,92	
50			Positivo	97458	1060	0,92	
51			Positivo	94472	1011	0,86	
52			Positivo	80251	914	0,83	
53			Positivo	90487	996	0,87	
54			Positivo	90487	996	0,87	
55			Positivo	97157	1030	0,87	
56			Negativo	72849	1797	3,53	O excesso de luminosidade na lâmina prejudicou a segmentação da imagem.
57			Negativo	***	***	***	O excesso de luminosidade na lâmina prejudicou a segmentação da imagem.
58			Positivo	91421	1021	0,90	
59			Positivo	92230	991	0,85	

60			Positivo	77620	911	0,85	
61			Positivo	93346	1012	0,87	
62			Positivo	96411	1023	0,86	
63			Negativo	62566	1567	3,12	A coloração do objeto muito semelhante a coloração do fundo da amostra prejudicou a segmentação da imagem.
64			Negativo	97250	1238	1,25	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
65			Positivo	92567	1006	0,87	
66			Positivo	88896	1026	0,94	
67			Negativo	90108	1227	1,13	A coloração do objeto muito semelhante a coloração do fundo da amostra prejudicou a segmentação da imagem.
68			Positivo	94841	1095	1,00	
69			Negativo	82772	1133	1,23	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
70			Positivo	76561	922	0,88	
71			Positivo	93192	1016	0,88	
72			Positivo	94522	1141	1,09	O excesso de sujeira na lâmina prejudicou a segmentação da imagem.
73			Positivo	90049	988	0,86	

74			Positivo	87935	986	0,88	
75			Positivo	92510	1031	0,91	
76			Positivo	89735	967	0,83	
77			Positivo	85,928	947	0,83	
78			Positivo	82740	935	0,84	
79			Negativo	34571	1286	3,80	A coloração do objeto muito semelhante a coloração do fundo da amostra prejudicou a segmentação da imagem.
80			Positivo	93194	1062	0,96	
81			Positivo	93423	1031	0,90	
82			Negativo	72571	1577	2,73	A coloração do objeto muito semelhante a coloração do fundo da amostra prejudicou a segmentação da imagem.
83			Positivo	91235	1060	0,98	
84			Positivo	88953	980	0,86	
85			Positivo	93490	1015	0,88	