



Universidade de Pernambuco  
Escola Politécnica de Pernambuco  
Departamento de Sistemas e Computação  
Programa de Pós-Graduação em Engenharia da Computação

André Caetano Alves Firmo

**Utilização de um Particle Swarm  
Optimization para otimização do método  
de diagnóstico da Esquistossomose  
Mansônica no litoral de Pernambuco**

**Dissertação de Mestrado**

Recife, julho de 2010

Universidade de Pernambuco  
Departamento de Sistemas e Computação  
Programa de Pós-Graduação em Engenharia da Computação

André Caetano Alves Firmo

**Utilização de um Particle Swarm  
Optimization para otimização do método  
de diagnóstico da Esquistossomose  
Mansônica no litoral de Pernambuco**

Dissertação apresentada como requisito parcial para  
obtenção do grau de Mestre em Engenharia da Computação.

Prof. Dr. Carmelo j. A. Bastos Filho  
Orientador

**Recife, maio de 2010**

## **Abstract**

With the advancement of schistosomiasis in the State of Pernambuco and the discovery of outbreaks in the coastal region, there is a need for further actions to the containment of the disease. One of control measures is the identification and treatment of sick people. Faster diagnosis and effective organisation is of the utmost priority to break the cycle and eradication of the outbreak. This work will be presented with a proposal for implementation of a system for identifying and counting the eggs of *Schistosoma Mansoni* apartir of porposta a image acquisition device collected from stool samples blades. The system is based on pattern recognition and trained from a technique of swarm of particles.

## **Resumo**

Com o avanço da esquistossomose no estado de Pernambuco e a descoberta de focos na região litorânea, são necessárias novas ações para a contenção da doença. Uma das medidas de controle é a identificação e o tratamento das pessoas doentes. O diagnóstico mais rápido e eficiente é de extrema prioridade para a quebra do ciclo e erradicação da epidemia. Neste trabalho será apresentada uma proposta de implementação de um sistema de identificação e contagem dos ovos de *Schistosoma Mansoni* a partir da proposta de um dispositivo de aquisição de imagens coletadas de lâminas de amostras de fezes. O sistema é baseado em reconhecimento de padrões e treinado a partir de uma técnica de enxame de partículas.

# Sumário

<b>Índice de Figuras</b>	<b>viii</b>
<b>Índice de Tabelas</b>	<b>ix</b>
<b>Tabela de Símbolos e Siglas</b>	<b>x</b>
<b>1 Introdução</b>	<b>12</b>
1.1 Caracterização do Problema	12
1.2 Objetivos e Metas	13
1.3 Metodologia e Estratégia de Ação	14
1.4 Organização do texto e Roadmap	15
<b>2 Tópicos sobre Esquistossomose</b>	<b>16</b>
2.1 Visão geral	16
2.2 Ciclo da doença	18
2.3 Sintomas	21
2.4 Diagnóstico	21
2.5 Tratamento	22
<b>3 Processamento de Imagens</b>	<b>24</b>
3.1 Introdução	24
3.2 Sistema de processamento de imagens	25
3.3 Imagem digital	25
3.4 Aquisição de imagem	28
3.5 Melhoramento na Imagem (Pré-processamento)	29
3.6 Segmentação de imagem	31
3.7 Extração de atributos	34
3.8 Classificação e reconhecimento de padrões	34
<b>4 Classificação e Detecção</b>	<b>36</b>
4.1 OpenCV	36
4.2 Método de detecção de face por Viola-Jones	37
4.3 Imagem Integral	38
4.4 Características	40
4.5 Classificador Fraco	41
4.6 Algoritmo de Aprendizado	41
4.6.1 AdaBoost	42
4.7 Cascata de classificadores	43
4.8 Treinamento da cascata de classificadores	44
<b>5 Otimização e Treinamento</b>	<b>46</b>
5.1 Otimização	46
5.2 Otimização por enxame de partículas	47
5.2.1 Funcionamento do PSO	48
5.2.2 Principais propostas de melhorias	50

<b>6</b>	<b>Modelo Proposto</b>	<b>52</b>
6.1	Proposta de trabalho	52
6.2	Arranjos Experimentais	53
6.2.1	1ª Fase – Aquisição e pré-processamento de imagem.	53
	<b>Conclusões e Trabalhos Futuros</b>	<b>60</b>

# Índice de Figuras

Figura 1. Modelo de mobilidade Random Walk	14
Figura 2. Modelo de mobilidade de Gauss-Markov	14
Figura 3. Modelo de mobilidade RPGM	15
Figura 4. Modelo de mobilidade Nomadic Community	16
Figura 5. Modelo de mobilidade Random Waypoint	19
Figura 6. Função distribuição de probabilidade uniforme para escolha das velocidades dos nós.	23
Figura 7. Distância (R) versus Velocidade (V).	24
Figura 8. Distribuição BETA(2,2) de probabilidade para escolha das velocidades dos nós	29
Figura 9. Distribuição BETA(2,1) de probabilidade para escolha das velocidades dos nós	30
Figura 10. Variação de $V_{sim}$ com o tempo de simulação para algumas distribuições BETA.	42
Figura 11. Comportamento do RWP conforme as distribuições BETA(1,1), BETA(2,1) e BETA(2,2) em simulações C++.	45
Figura 12. Número de pacotes de controle de roteamento em função do tempo de simulação.	48
Figura 13. Número de pacotes de dados descartados em função do tempo de simulação.	48

# Índice de Tabelas

Tabela 1. Variação de  $\bar{v}_{modif}$  quando  $V_{min} \rightarrow 0$ , para vários valores de  $\alpha$  e  $\beta$ .

41

Tabela 2. Comparação entre velocidades em unidades de m/s (analítico e simulação).

46

# Tabela de Símbolos e Siglas

RoadMap – Mapa de Navegação.

PSO – Particle Swarm Optimization.

S. mansoni – Schistosoma mansoni.

AdaBoost – Adaptative Boost.

Pixel – Picture Element.

Grayscale – Tons de cinza.

# Agradecimentos

Gostaria de agradecer à Deus por ter me dado forças para concluir mais esta etapa no meu desenvolvimento profissional e pessoal.

A minha família por estar sempre contribuindo para meu desenvolvimento pessoal. Aos meus filhos, Gabriel e Rafael, que me dão motivação e inspiração a tentar ser um exemplo como: pai, profissional e amigo. A minha esposa, Juliana, que me deu suporte cuidando de tudo e me proporcionando tempo para concluir os estudos. A minha querida avó, Enelídia, que partiu antes que eu pudesse concluir este trabalho mas que me deixou grandes ensinamentos e muitas saudades.

Aos amigos, Murilo e Arthur, que me ajudaram nos ensaios experimentais e que sem o suporte dessa turma eu não teria conseguido concluir este trabalho.

Aos Professores, Jones Albuquerque e Carmelo Bastos, que acreditaram no meu potencial e me proporcionaram a oportunidade de contribuir com este estudo para a melhoria dos serviços em saúde pública.

Aos amigos, Barnabé e Fernando, técnicos do laboratório de esquistossomose da Fio Cruz que me auxiliaram na coleta das imagens e do material laboratorial. A Constança que me disponibilizou o acesso e a infraestrutura do laboratório de esquistossomose da Fio Cruz.

E a todos que direta ou indiretamente me influenciaram de alguma maneira na conclusão deste trabalho.

# Capítulo 1

## Introdução

O presente trabalho tem como escopo principal o desenvolvimento de um sistema de detecção de imagens para contagem de ovos de *Schistosoma mansoni* em exames de fezes. O treinamento do sistema é otimizado usando-se uma técnica de enxame de partículas proporcionando maior velocidade e precisão no diagnóstico da esquistossomose.

### 1.1 Caracterização do Problema

A Esquistossomose mansônica afeta cerca de 200 milhões de pessoas em várias regiões do mundo. Segundo Katz e Peixoto [1], no Brasil, a doença é considerada uma endemia e apresenta de 2,5 a 6 milhões de indivíduos parasitados. Sua distribuição é observada na faixa litorânea que compreende desde a região Norte até a região Sul, apresentando-se como endêmica em vários estados do Nordeste. Segundo Kano [2], Pernambuco tem a segunda maior prevalência entre os estados nordestinos, representando 15,2% da região. Nesse estado, a esquistossomose é historicamente endêmica na região rural, em localidades onde as taxas de infecção humana variam de 12% a 82%.

A prevalência e a intensidade da infecção nas comunidades de Pernambuco afetadas pela doença estão condicionadas a práticas culturalmente moldadas como: atividades econômicas, de lazer ou domésticas, peculiares em cada localidade aponta Barbosa [3].

Recentemente, casos humanos de infecção aguda têm sido detectados em regiões praieiras[3][4][5], onde a doença está sendo introduzida devido à ausência de planejamento socioeconômico na ocupação desses espaços. Este fato tem sido comprovado através de focos de vetores da esquistossomose encontrados em localidades litorâneas do estado, além de novos sítios de transmissão ativa da doença detectados em praias de turismo e veraneio de classe média alta.

Levantamentos malacológicos realizados em municípios do litoral pernambucano apontam 12 novos focos de esquistossomose em localidades praianas do Estado [3][4][5].

O método de diagnóstico através do exame parasitológico de fezes ainda é a melhor alternativa por ter uma boa sensibilidade e um menor custo de operação. Neste método ainda não há uma ferramenta automatizada que auxilie na contagem dos ovos de *S. mansoni*, necessitando de um profissional devidamente qualificado para tal trabalho.

As técnicas de inteligência computacional são capazes de proporcionar maior desempenho e eficiência no treinamento de sistemas baseados em técnicas de reconhecimento de padrões. Tais sistemas são uma boa alternativa para o desenvolvimento de uma ferramenta que auxilie na automatização da contagem de ovos de *S. Mansoni* a partir de exames parasitológico de fezes com o objetivo de diagnosticar a esquistossomose.

## 1.2 Objetivos e Metas

A partir dos altos índices de contaminação encontrados no litoral Pernambucano, um método de diagnóstico mais rápido e eficiente é de extrema prioridade para a contenção e diagnóstico da doença. Neste projeto de pesquisa será proposto um sistema automatizado que seja capaz de auxiliar na contagem dos ovos de *S. Mansoni* e identificar os níveis de contaminação da esquistossomose no litoral Pernambucano.

A proposta do sistema está dividida em 2 (duas) partes:

- O desenvolvimento de um método para a aquisição das imagens das lâminas laboratoriais dos exames de fezes. Para esta etapa podem-se destacar como principais requisitos: a utilização de equipamentos (câmera) que sejam capazes de capturar imagens com uma boa resolução e com menor custo possível; a implementação de um sistema de acoplamento do equipamento utilizado ao microscópio que não modifique suas características físicas.
- A implementação de um software capaz de identificar e contar os ovos de *S. mansoni* a partir das imagens capturadas na etapa anterior. Para esta etapa podem-se destacar como principais requisitos: a utilização de técnicas que permitam um tempo de processamento e de resposta cada vez menores; a definição de comandos simples visando uma menor dependência do utilizador.

## 1.3 Metodologia e Estratégia de Ação

Através de uma parceria entre o grupo de pesquisa Xiscanoé [25], Departamento de Sistemas e Computação da Escola Politécnica – UPE e o Laboratório de Esquistossomose do Departamento de Parasitologia da CpqAM/FIOCRUZ, serão utilizadas as estruturas físicas e de apoio da FIOCRUZ bem como a disponibilização das lâminas dos exames parasitológicos de fezes de pessoas com suspeita da esquistossomose como conjunto de dados para o desenvolvimento desta pesquisa. A execução deste projeto está dividida em 3 fases distintas:

1. Na primeira fase foram analisadas as soluções em hardware para a aquisição das imagens das lâminas dos exames parasitológicos dos infectados e realizado o pré-processamento das imagens adquiridas .
2. Na segunda fase foi implementado o sistema de detecção de imagens utilizando a biblioteca OpenCV [11] e a proposta desenvolvida por Viola e Jones [15] para detecção de objetos.
3. Na terceira etapa foi implementado um PSO [18] e aplicá-lo ao sistema de reconhecimento e contagem dos ovos de *S. Mansoni*, com o objetivo de otimizar o sistema.

Segue um breve resumo de cada fase do projeto.

**Primeira fase** – Nesta fase foram analisados as opções de dispositivos que serviram como aquisição das imagens das lâminas dos exames parasitológicos de fezes dos infectados. Foi definida a utilização de uma webcam com características pré-definidas, no intuito de obter uma melhor qualidade das imagens. Esta webcam foi acoplada ao microscópio e capturada uma foto de cada seguimento da lâmina. A imagem passa por um processo de filtragem onde serão aplicados filtros que minimizam os ruídos e efetivamente configurará as melhores características das primitivas da imagem: contraste, brilho, saturação e matiz. Ao término desta primeira fase o produto será um arquivo de imagem devidamente preparada para que o sistema inteligente possa identificar e contar os ovos de *S. mansoni*.

**Segunda fase** – Nesta fase foram analisadas as técnicas de reconhecimento de padrões e elegida a que melhor se adaptou para a resolução do problema proposto. A proposta inicial para esta fase era analisar as técnicas mais utilizadas como: as redes neurais, os classificadores KNN e bayesiano e as árvores de decisão. A partir da eleição da técnica, foi implementada a técnica e definido o conjunto de características do ovo de S. Mansoni que foram utilizadas como o padrão a ser reconhecido pelo sistema. A partir deste ponto, foi preparado um conjunto de ensaios utilizando as imagens resultantes da fase anterior para calibragem do sistema e definidos os níveis mínimos de aceitação e tolerância de erros do sistema. Ainda como atividade desta fase foram feitos os primeiros registros de desempenho e eficiência do sistema.

**Terceira fase** – Nesta fase foi analisada a proposta de utilizar um PSO para otimização do treinamento do sistema. Foi realizado o acoplamento entre o PSO e a técnica de reconhecimento de padrões utilizada no sistema. Ao término deste processo, foi feito os ajustes necessários para que o sistema identifique e conte os ovos do S. Mansoni e testados os desempenhos do novo sistema com o conjunto de imagens resultantes da primeira fase deste projeto.

## 1.4 Organização do texto e Roadmap

Este trabalho está estruturado em seis capítulos, incluindo esta introdução.

O segundo capítulo apresenta uma visão geral sobre a esquistossomose e as principais formas de diagnóstico.

O terceiro capítulo apresenta os principais tópicos sobre processamento de imagem.

O quarto capítulo trata do mecanismo de classificação e detecção de objetos.

O quinto capítulo mostra os principais tópicos sobre a técnica de otimização por enxame de partículas.

O sexto capítulo descreve a proposta de trabalho e a metodologia aplicada.

O sétimo capítulo mostra os resultados de exames realizados pelo sistema, comenta os resultados obtidos e sugere a continuação do trabalho através do desenvolvimento de instrumentos de baixo custo, derivados do projeto inicial.

Como sugestão de utilização deste material, foram mapeados 2 grupos de leitores e sugerido a leitura dos capítulos por relevância de interesses.

Profissionais e estudantes da área de saúde – leitura dos Capítulos: 3,6,7.

Profissionais e estudantes de engenharia e computação – leitura de todos os Capítulos.

# Capítulo 2


## Tópicos sobre Esquistossomose

Neste capítulo serão apresentados os aspectos biológicos e epidemiológicos da esquistossomose. O objetivo deste capítulo é promover uma visão geral sobre o cenário do problema abordado identificando as necessidades e mapeando os parâmetros para a elaboração da solução. Uma abordagem mais detalhada pode ser encontrada em Carvalho, Coelho e Lenzi [7].

### 2.1 Visão geral


A esquistossomose é uma infecção produzida por cada uma das três espécies de esquistossomo: *Schistosoma haematobium*, *Schistosoma japonicum* e *Schistosoma mansoni* e que tem, conforme o esquistossomo causador, características próprias e dependentes da localização deste. É também conhecida como esquistossomíase, bilharziose (homenagem ao bacteriologista alemão Theodor Bilharz, 1825-1862, professor da Escola de Medicina do Cairo, que, em 1851, descobriu e descreveu, no Egito, o esquistossômulo do *Schistosoma haematobium*) e, popularmente, barriga d'água.

Na esquistossomose mansônica o agente etiológico (agente que causa a doença) da esquistossomose mansoni é o esquistossomo (*Schistosoma mansoni*), um verme platelminto, da classe dos trematódeos, família dos esquistossomídeos, digenético (providos de duas ventosas) e sexuado, parasita do homem e de alguns mamíferos marsupiais, em cujas veias do sistema portal localizam-se os vermes adultos. A veia porta é aquela que conduz ao fígado o sangue venoso proveniente de vários órgãos abdominais (baço, estômago, intestino delgado, cólons, etc.). Também se diz apenas porta, portal. Na Figura 1 é mostrado o parasita *S. mansoni* na sua forma adulta.



**Figura 1.** *Schistosoma mansoni*: parasita na forma adulta.

Segundo estimativa da Organização Mundial da Saúde (OMS), 200 milhões de pessoas em 76 países sofrem de esquistossomose. No Brasil, o leste da Região Nordeste e o nordeste e leste do Estado de Minas Gerais convivem com a esquistossomose em situação endêmica. Os programas de controle do Ministério da Saúde conseguiram, até agora, diminuir a mortalidade e as formas mais graves da doença. Segundo estimativas do Ministério da Saúde, em 1993 foram detectados 272.728 casos. Em 1995, 11,1% do total de 2.715 259 pessoas examinadas no Brasil registraram a doença. No primeiro semestre de 1996, a proporção foi de 9% do total de 945.365 pessoas examinadas. Os exames ocorreram nas chamadas áreas esquistossomóticas, que compreendem parcialmente 18 estados e onde vivem cerca de 69 milhões de habitantes. Na Figura 2 é mostrada a distribuição da doença no território nacional.



**Figura 2.** Distribuição Geográfica da Esquistossomose Mansônica no Brasil.

## 2.2 Ciclo da doença

O hospedeiro elimina nas fezes o ovo que mede cerca de 114-175 por 45-68 micrômetros. Quando os ovos maduros atingem a água doce em condições adequadas, principalmente de temperatura e luz, ocorre a eclosão e liberam uma forma larvária ciliada denominada de miracídio que possui em média 180 x 62 micrômetros. Os miracídios nadam a procura do hospedeiro intermediário. Fora do hospedeiro, normalmente, o miracídio não sobrevive além de um dia (seis horas em média). Na Figura 3 é mostrado o ovo de *S. mansoni* e na Figura 4 o miracídio.




**Figura 3.** Ovo de *Schistosoma mansoni* contendo um miracídio.



**Figura 4.** Miracídio.

No seu ciclo evolutivo os miracídios mansônicos hospedam-se nos caramujos do gênero *Biomphalaria*, espécies de água doce (no Brasil o *B. glabrata*, o *B. straminea* e *B. tenagophila*), penetrando em qualquer parte descoberta destes moluscos, tendo preferência pela base das antenas ou pelo pé. Estes moluscos vivem principalmente em pequenas porções de águas paradas ou de fraca correnteza, onde haja luz solar e pouca poluição (riachos de pequena declividade e fundo arenoso, valas de irrigação, alagadiços, etc.).

Após penetração no caramujo, em 48 horas transformam-se em esporocistos primários, possuindo em seu interior as células germinativas. O período de vida dos esporocistos é de 18 a 21 dias. A partir do 14º dia de penetração do miracídio, no interior do esporocisto primário, inicia-se a formação dos esporocistos secundários ou rédias, que também possuem um aglomerado de células germinativas. As rédias passam a sofrer uma série de modificações, especialmente em seu crescimento e em seu interior, onde se dá o complicado processo de formação de uma grande quantidade de cercárias, pois cada miracídio que infesta o caramujo poderá resultar no final da transformação na impressionante soma de mais de 10 mil cercárias. No fim de 25 a 30 dias ou até um pouco mais, dependendo da temperatura da água em que vive o caramujo e da própria espécie deste, as cercárias começam a sair das rédias, a taxa aproximada de mil por dia, durante cerca de duas semanas no caso da mansônica, e nadam a procura dos hospedeiros vertebrados. Na Figura 5 é mostrado um caramujo do gênero *glabrata* e uma cercária.




**Figura 5.** (A) Caramujo do gênero *Biomphalaria glabrata* e (B) cercária.

Cada cercária é formada por um corpo e uma cauda que se bifurca na parte terminal. Mede cerca de 140 por 4 micrômetros, podendo viver até 48 horas, ou até 3 dias, na água. Penetrando pela pele do hospedeiro vertebrado, alcança a corrente sanguínea em 2 a 15 minutos, podendo também penetrar pela mucosa, quando água infectada é ingerida, embora esta forma de contágio seja muito menos significativa.

Em seguida migram para o intestino, contra a corrente sanguínea, e instalam-se nas vênulas da parede intestinal, onde permanecem constantemente acasalados, vivendo em média dois anos, mas em determinadas situações até 30 anos. Com um dia de infecção, é possível encontrar larvas nos pulmões e nove dias depois as mesmas rumam para o fígado, onde alimentam-se de sangue e iniciam sua maturação. No vigésimo dia, os vermes, já adultos, começam a se acasalar e sete dias depois a fêmea já libera os primeiros ovos.

Cada fêmea pode produzir em média 300 ovos por dia. Destes ovos provenientes das fêmeas cerca de 20% caem no tubo intestinal e são eliminados com as fezes. Porém, na sua maioria, são retidos pelos tecidos, após serem carregados pelos vasos sanguíneos, dando origem aos granulomas (massa de tecido não tumoral, com características proliferativas, fibrosantes e degenerativas, que se desenvolve, muitas vezes, em diferentes inflamações crônicas). Do momento da penetração da cercária até o início da produção de novos ovos completa-se um intervalo em torno de 1 a 2 meses, denominado de período de incubação. Em média, apenas após o quadragésimo dia de infecção será possível encontrar ovos de *S. mansoni* nas fezes do enfermo. Na Figura 6 é apresentado o ciclo da doença em seis fases distintas.



**Figura 6.** Ciclo da Esquistossomose.

## 2.3 Sintomas

Os sintomas mais comuns são mal-estar, febre, dor de cabeça, perda do apetite, suor intenso, tosse, diarreia com ou sem dolorimento abdominal. Nos casos crônicos há dor abdominal, dificuldade de digestão e náuseas. Os sintomas mais agudos surgem quando os vermes amadurecem no organismo humano, após quatro a seis semanas da infecção, mas não é raro, na sua passagem pelos pulmões, provocarem febres e problemas respiratórios. Dependendo do grau de infestação, o fígado pode aumentar muito de tamanho e o doente fica com a barriga inchada, daí a denominação de barriga d'água.

A duração desta fase estende-se até 40 a 60 dias quando começam a aparecer os primeiros ovos nas fezes, evidenciando a maturação dos parasitas e o quadro febril declina lentamente. O paciente passa, então, para a fase crônica com diarreias, evacuações mucosanguinolentas e cólicas abdominais. Em casos mais graves, devido a fibrose extensa do fígado, ocorre hipertensão da circulação portal - acumula-se sangue no baço e aparecem varizes no esôfago, órgãos cujas veias desembocam no sistema porta. A ruptura das varizes esofágicas provoca hemorragias extensas (hematêmese) e muito graves. A desnutrição dos pacientes é devida não só a anemia decorrente das hemorragias, mas também ao funcionamento insuficiente do fígado. A cura exige medicamentos específicos.

## 2.4 Diagnóstico

O diagnóstico é uma das maiores barreiras para o tratamento e controle da doença. Atualmente os métodos para o diagnóstico da esquistossomose são:

- Exame parasitológico de fezes - ovos de *S. mansoni* podem ser encontrados nas fezes, a partir do 40º dia do contágio, sendo a técnica de sedimentação espontânea utilizada para identificação dos mesmos em ovos viáveis ou não, para pacientes atendidos nos serviços de saúde. Os ovos são de 114 a 175 mm de comprimento e de 45 a 68 mm de espessura, tendo uma espinha lateral proeminente. O método de Kato-Katz [6] é utilizado em inquéritos coproscópicos e investigações epidemiológicas devido à sua facilidade operacional em campo e por permitir a quantificação de ovos por grama de fezes.
- Biópsia retal - a biópsia é um método de fácil execução e indolor, porém por ser uma técnica invasiva, é pouco utilizada. Na esquistossomose crônica, sem hipertensão portal,

uma biópsia retal apresenta cerca de 80% de positividade enquanto que no exame de fezes, 50%.

- Outros - biópsia de órgãos comprometidos, *e.g.* biópsia hepática é destinada a casos especiais, quando se necessita conhecer o quadro histológico do fígado, em formas agudas ou hepatoesplênicas, ou para diagnóstico diferencial.
- Reações sorológicas - o diagnóstico utilizando soro do paciente para detecção de IgG e IgM contra *S. mansoni* pode indicar infestação atual ou passada. Existem vários tipos de reações sorológicas para a esquistossomose, mas não têm ampla aplicação na prática. Elisa e imunofluorescência são utilizados em estudos clínicos e experimentais.
- Intradermoreação - consiste na inoculação de antígeno geralmente preparado com vermes adultos ou cercárias, na face anterior do antebraço, na quantidade de 0,01 a 0,05 ml. Sua interpretação é feita 15 minutos após a inoculação. Este método não tem sido utilizada na prática.

Outros exames por imagens como ultra-sonografia hepática e ressonância magnética da medula espinhal estão sendo utilizados no diagnóstico da doença. Estas e outras propostas são descritas por Carvalho, Coelho e Lenzi [7]. Rabello [8] propõe novas abordagens para o diagnóstico da esquistossomose em casos crônicos.

## 2.5 Tratamento

O tratamento é feito, sobretudo, por meio da administração de medicamentos como o oxamniquine ou o praziquantel, porém, a melhor maneira de enfrentar a esquistossomíase e evitar que ela aconteça. Para tanto, faz-se necessária uma extensa política de saúde pública e sanitária, já que a esquistossomíase está diretamente ligada a problemas sócio-econômicos. Portanto, controlar a existência da *Biomphalaria* não é suficiente, é preciso melhorar a qualidade de vida das populações e tomar medidas sanitárias, como, por exemplo, a construção de sistemas adequados de esgoto. Na Figura 7 é mostrado um caso de prevalência crônica da esquistossomose.



**Figura 7.** Caso de prevalência crônica.

# Capítulo 3

## Processamento de Imagens

Neste capítulo serão apresentados os principais conceitos sobre o processamento de imagens. O objetivo deste capítulo é reunir as principais ferramentas de processamento de imagem, servindo como suporte para a implementação da solução de detecção de ovos de *S. mansoni*. Para maior detalhamento sobre os tópicos abordados consulte Gonzalez e Woods [9] e Acharya e Ray [10].

### 3.1 Introdução

O crescente avanço da tecnologia proporcionou ao homem ferramentas para a difusão de conhecimento e armazenamento de informações. O processamento dos dados (informações) na forma de imagens é denominado de Processamento de imagens. Processar uma imagem consiste em transformá-la sucessivamente através de um conjunto de operações matemáticas (algoritmos) com o objetivo de extrair a informação nela contida. Esse trabalho é realizado pelo sistema visual humano (SVH) de maneira extremamente complexa. Realizar as mesmas tarefas que o SVH, com a ajuda de máquinas, exige por antecedência uma compreensão “filosófica” do mundo ou dos conhecimentos humanos. Esta característica faz com que o processamento de imagens tenha uma extrema dependência do sistema no qual ele está associado, não existindo no entanto uma solução única e abrangente para todos os problemas. Daí a não existência, até o momento, de sistemas de análise de imagens complexos e que funcionem para todos os casos.

## 3.2 Sistema de processamento de imagens

Um sistema de processamento de imagens pode ser dividido em módulos independentes. Cada módulo possui uma função específica e funcionamento encadeado, onde a saída do módulo anterior é a entrada do próximo módulo. Na Figura 8 é apresentado o modelo de um sistema de processamento de imagens com as saídas por módulos.




Figura 8. Modelo de um sistema de processamento de imagens.


## 3.3 Imagem digital

No mundo real a representação dos sinais (imagens) podem ser descritos como uma função contínua. O computador só é capaz de armazenar bits, um valor que pode ser 0 ou 1. Convencionou-se que 8 bits formam uma palavra chamada de byte. Um byte então pode assumir  $2^8 = 256$  valores diferentes, variando de 0 a 255.

Assim, o computador trabalha sempre com números inteiros ou com uma aproximação de um número real, chamada de ponto flutuante (isso porque o número de bits dedicado para as casas decimais é flexível de acordo com o número). Por conseqüência, não é possível representar uma função contínua no computador. Podemos apenas simula-la.


O processo para trazer uma função contínua para o computador é discretizando-a (ou digitalizando-a), tomando valores pontuais ao longo de  $x$  e guardando o valor de  $f(x)$  correspondente. O processo de discretização do eixo  $x$  (o domínio) é chamado de Amostragem, o do eixo  $f(x)$  (o contradomínio) é chamado de Quantização.

A amostragem mais comum é chamada de uniformemente espaçada, pois cada amostra é tomada em intervalos iguais. Na Figura 9 é mostrada a amostragem em um sinal contínuo.



**Figura 9.** Amostragem de um sinal contínuo.


A quantização mais comum consiste em tomar o valor máximo e o valor mínimo da função, e dividir este segmento em intervalos iguais de acordo com o número de bits definido para armazenar uma amostra. Assim, o número de valores possíveis será  $2^{\text{nbits}}$ . A Figura 10 ilustra a quantização da amostragem de um sinal.




**Figura 10.** Quantização da amostragem de um sinal.

A representação de uma imagem digital é a matriz  $M \times N$  de números reais resultado da amostragem e quantização de uma dada função (sinal). Um ponto da matrix é denominado de pixel ("picture element" ou "pel") é o elemento básico em uma imagem digital. A forma mais comum para o pixel é a forma retangular ou quadrada. Um pixel não apresenta as mesmas

propriedades em todas as direções, i.e., ele é anisotrópico. Esta propriedade faz com que um pixel tenha 4 vizinhos de borda e 4 vizinhos de diagonal. Esta propriedade força a definição do tipo de conectividade D4 (considerando apenas os vizinhos de borda) ou D8 (considerando os vizinhos de borda e os de diagonal). Na Figura 11 mostra o mapeamento de um pixel em uma imagem e a matriz de pontos. Na Figura 12 é mostrada a conectividade D4 e D8.




**Figura 11.** Pixel e matrix de pontos.



**Figura 12.** Conectividade D4 (a) e D8 (b).

O nível de detalhamento que uma imagem pode apresentar é definido como resolução da imagem. a resolução em pixels como o conjunto de dois números positivos inteiros, em que o primeiro número é a quantidade de colunas (largura) de pixels e o segundo é número de linhas (altura) de pixels. E.g. 640 x 480. A Figura 13 exhibe uma imagem em várias resoluções quadradas  $n \times n$ .




**Figura 13.** Exemplo de imagem em várias resoluções.

### 3.4 Aquisição de imagem

O primeiro estágio em um sistema de processamento de imagens é a aquisição ou captura da imagem real. Neste estágio existem basicamente 2 componentes: Um sensor responsável por produzir um sinal elétrico (analogico) proporcional a intensidade de luz captada e um digitalizador responsável por converter a saída elétrica em informação digital. O equipamento mais utilizado para aquisição de imagens é a câmera de vídeo.

Há dois tipos principais de sensores o CCD e o CMOS.

Os sensores CCD (charged coupling device) são formados por uma grande quantidade de pequenos foto diodos, chamados de photosites. A variação elétrica é acumulada na célula e transportada para gravação após a devida conversão pelo circuito auxiliar de digitalização. A Figura 14 exemplifica a estrutura de um sensor CCD.



**Figura 14.** (A) Sensor CCD e (B) Circuito Auxiliar.

O processo de fabricação dos sensores CCD foi desenvolvido usando uma metodologia diferenciada que proporcionam a criação de imagens com alta sensibilidade a luz e menor quantidade de ruído.

Os sensores CMOS são constituídos por vários transistores que amplificam o sinal luminoso e permitem a leitura de cada pixel individualmente. O processo de fabricação dos chips CMOS é idêntico aos da maioria dos microprocessadores, onde a miniaturização permitiu que além do sensor outros circuitos como o digitalizador pudessem ser incluídos no mesmo envólucro. Os chips CMOS são menos sensíveis a luz, possuem menor qualidade e são suscetíveis a ruídos. O consumo de energia dos chips CMOS é menor do que os chips CCD. A Figura 15 exemplifica um envólucro de um sensor CMOS.




Figura 15. Sensor CMOS.


### 3.5 Melhoramento na Imagem (Pré-processamento)

A extração de informação da imagem adquirida na etapa anterior pode não ser uma tarefa simples. Vários motivos podem dificultar a interpretação da informação contida na imagem pelas etapas de reconhecimento. Destacam-se como principais causadores de ruídos : o tipo do sensor utilizado na aquisição, a iluminação do ambiente e a posição relativa entre o objeto de interesse e a câmera. Na etapa de pré-processamento são usadas algumas ferramentas a fim de minimizar o ruído e preparar a imagem para as etapas de reconhecimento.

Há várias ferramentas para o pré-processamento de imagens, podemos destacar as seguintes:


**Filtros** – são técnicas que realçam ou atenuam características na imagem. Esses filtros podem ser utilizados no domínio de espaço (ondem alteram diretamente os pixels da imagem) ou no domínio da frequência (onde é utilizada a transformada de Fourier, aplicado os filtros e depois

transformada a imagem novamente para o domínio do espaço). A Figura 16 mostra a aplicação de um filtro de distorção utilizado no domínio de espaço.




**Figura 16.** (A) imagem original, (B) imagem com aplicação de filtro de distorção.

**Grayscale** – Uma outra ferramenta bastante utilizada e a transformação de imagens coloridas para o domínio de tons de cinza. Uma imagem em tons de cinza possui para cada pixel apenas a informação de intensidade, onde podem ter mais intensidade (perto da cor branca) ou menos intensidade (perto da cor preta). Este tipo de representação das cores minimiza a quantidade de cálculos por pixel e elimina alguns tipos de ruídos. A Figura 17 mostra a aplicação de Grayscale em um imagem.




**Figura 17.** (A) imagem original, (B) Imagem em grayscale.

**Equalização de Histograma** – Um histograma é a representação gráfica da distribuição de cada intensidade por pixel. A equalização do histograma consistem em mapear os valores das intensidades dos pixels entre uma região com pouco contraste e uma com muito contraste e distribuir de maneira uniforme os pixels ao longo da imagem obtendo uma imagem equalizada. A Figura 18 mostra a aplicação de uma equalização de histograma em uma imagem e na Figura 19 é exibido o histograma da imagem resultante.



**Figura 18.** (A) imagem original, (B) imagem com correção por histograma.




**Figura 19.** Histograma.

### 3.6 Segmentação de imagem

Após a imagem estar devidamente tratada e pronta para ser utilizada pela etapa de reconhecimento, se faz necessário uma etapa intermediária para restringir a região da imagem a ser analisada. Na etapa de segmentação é realizado um particionamento da imagem guiado por


características do objeto ou região de interesse. Há diversas técnicas de segmentação de imagens, onde destacam-se:

**Segmentação por detecção de borda** – A definição de borda em uma imagem pode ser resumida como a variação subta dos níveis de intensidade dos pixels. Os detectores de borda são caracterizados por detectar essas variações nos pixels e quando estes pixels esntão próximos eles podem ser conectados formando um contorno e assim definindo uma região ou objeto. A Figura 20 ilustra a segmentação por detecção de bordas.




**Figura 20.** (A) imagem original e (B) Segmentação por detecção de bordas.

**Segmentação por corte** – Neste tipo de abordagem é realizada no histograma da imagem a verificação da quantidade de regiões existentes (picos e vales) e segmenta-se a imagem baseado nesta informação. Esta metodologia é de simples implementação e utiliza-se de propriedades intuitivas para a criação das imagens segmentadas sendo bastante rápida e com baixo custo computacional. A Figura 21 ilustra a aplicação da segmentação por corte.



**Figura 21.** (A) imagem original e (B) Segmentação por corte.

**Segmentação baseada em crescimento de região** – Neste tipo de abordagem são encontradas as regiões diretamente na imagem a partir do agrupamento de pixels ou sub-regiões em regiões maiores baseado em critérios pré-definidos. O princípio desta proposta é a determinação de um conjunto de pontos (sementes) onde a partir destes pontos agrupa-se outros pontos baseados em uma vizinhança de influência, formando a regiões. Nesta vizinhança são analisadas propriedades e são medidas similaridades para determinar se o pixel faz parte ou não da região sendo considerada. As propriedades normalmente consideradas são: cor, intensidade de nível de cinza, textura e momentos. A Figura 22 mostra a segmentação por região de crescimento.



**Figura 22.** (A) imagem original e (B) Segmentação por região de crescimento.

## 3.7 Extração de atributos

A partir das imagens pré-processada e segmentadas é possível extrair atributos que caracterizem a região ou objeto de interesse. Os atributos típicos são:

**Número de objetos** – É a quantização dos objetos de interesse na região segmentada.

**Propriedades geométricas** – são características particulares em relação a forma do objeto de interesse, como: área, perímetro, centro de gravidade, largura máxima e mínima.

**Propriedades de luminância** – são dados relativos aos níveis de intensidade de cinza médio de cada região, desvio padrão e momentos estatísticos da distribuição de cada região.

**Propriedades associadas à textura** – são dados obtidos a partir da textura e padrão de cores da região de interesse.

## 3.8 Classificação e reconhecimento de padrões

Com as características definidas, o objetivo da etapa de de classificação é distinguir os objetos na imagem agrupando os parâmetros de acordo com sua semelhança para cada região de pixels encontrada. Essa classificação é feita ponderando sempre através de uma medida de erro de classificação. A classificação é uma etapa complexa existindo diversos níveis de automação.

Os processos mais simples implicam no agrupamento estatístico onde a decisão humana é fundamental. Os processos mais sofisticados utilizam técnicas de inteligência computacional onde não é necessário nenhuma intervenção humana.

Há várias técnicas para a implementação de classificadores. Das técnicas mais difundidas podemos destacar:

**K-médias** – método de agrupamento não-hierárquico por repartição, onde produz k diferentes conjuntos com a maior distinção possível entre eles.

**Árvores de decisão** – método preditivo onde cada ramo da árvore é uma questão de classificação e cada folha é uma partição do conjunto de dados com sua classificação.

**Redes neurais artificiais** – técnica computacional inspirada na estrutura neural que adquire conhecimento a partir da experiência. É composta por várias unidades de processamento denominadas neurônios. Os neurônios são conectados por canais de comunicação que estão associados a pesos e realizam operações sobre seus dados locais. O comportamento inteligente de uma rede neural artificial vem da interação entre as unidades de processamento da rede.


**Classificadores bayesianos** – método estatístico que classifica um objeto a uma determinada classe baseando-se na probabilidade deste objeto pertencer a esta classe.

**Suporte a vetor de decisão** – nesta técnica a separação entre classes do conjunto de treinamento é feita a partir de um hiperplano que é determinado por alguns pontos os quais são denominados vetores de suporte.

O reconhecimento de padrões implica no processo onde existe algum conhecimento prévio e algum tipo de armazenamento de conhecimentos sobre o objeto a ser reconhecido. Para o reconhecimento é necessário uma base de conhecimento dos objetos a serem reconhecidos. Esta base pode ser implementada diretamente no código através de regras ou pode ser aprendida a partir de um conjunto de amostras dos objetos a serem reconhecidos por um classificador.

Um objeto pode ser definido por mais de um padrão (textura, forma, cor, dimensões, etc) e o reconhecimento individual de cada um destes padrões pode facilitar o reconhecimento do objeto como um todo.

As técnicas de reconhecimento de padrões podem ser divididas em dois grandes grupos: Estruturais, onde os padrões são descritos de forma simbólica e a estrutura é a forma como estes padrões se relacionam. O outro grupo é baseado em técnicas que utilizam teoria de decisão, neste grupo os padrões são descritos por propriedades quantitativas e deve-se decidir se o objeto possui ou não estas propriedades. Na Figura 23 é apresentado um exemplo de detecção de faces de gatos.



**Figura 23.** Detecção de face de gatos.

# Capítulo 4

## Classificação e Detecção

Neste capítulo será apresentado os conceitos propostos por Viola e Jones [15] utilizando a biblioteca OpenCV [11] que serviram como fundamentos para o desenvolvimento do sistema proposto neste trabalho. O objetivo deste capítulo é exibir as principais ferramentas utilizadas na elaboração da solução de detecção.

### 4.1 OpenCV

A OpenCV [11] (Open Computer Vision Library) é uma biblioteca multiplataforma de uso livre para o desenvolvimento de aplicativos na área de visão computacional e processamento de imagens. Foi desenvolvida pela Intel possui mais de 500 funções escritas em C/C++ que possibilitam a usuários e programadores maior acesso a recursos entre humano-computador em tempo real e robótica. A biblioteca está disponível com o código fonte e executáveis (binários) otimizados para uso com os processadores Intel. Um programa utilizando OpenCV, ao ser executado, invoca automaticamente uma DLL (Dynamic Linked Library) que detecta o tipo do processador e carrega a DLL otimizada. Juntamente com o pacote OpenCV é oferecida a biblioteca IPL (Image Processing Library), da qual a OpenCV depende parcialmente, além de documentação e um conjunto de códigos de exemplo.

A biblioteca está dividida em cinco grupos de funções:


**CV** – contém os componentes básicos de alto-nível para processamento de imagens e visão computacional.

**ML** – contém a biblioteca de aprendizagem de máquina incluindo classificadores estatísticos e ferramentas de cluster.

**HighGUI** – Contém as rotinas de Entradas e Saídas e funções de armazenamento e leitura de imagens e vídeos.

**CvAux** – Contém algoritmos experimentais.

Na Figura 24 há a exemplificação dos módulos da biblioteca OpenCV. Como o módulo CvAux é composto de funções experimentais, ele não é referenciado na estrutura base.




**Figura 24.** Estrutura da Biblioteca OpenCV.

## 4.2 Método de detecção de face por Viola-Jones

Viola e Jones [15] desenvolveram uma metodologia para detecção de face e objetos que permite uma implementação rápida e robusta. O modelo fornece três contribuições básicas:

1. Uma nova forma de representação de imagens chamada de Integral Image.
2. Uma metodologia de seleção de características Haar básicas na Integral Image a partir de um algoritmo de aprendizagem boosting chamado AdaBoost.
3. A geração de uma estrutura de vários classificadores fracos baseado em árvores de decisão interligados em cascata formando um classificador forte.

Essa nova metodologia proporcionou um sistema com altas taxas de detecção e um rápido tempo de respa na detecção de objetos em tempo real. A Figura 25 mostra a estrutura proposta por Viola e Jones [15].




**Figura 25.** Estrutura proposta por viola e Jones.

### 4.3 Imagem Integral

Viola e Jones [15] desenvolveram uma nova forma de representação de imagem chamada de imagem integral. Essa representação é descrita como a localização  $(x,y)$  contendo a soma dos valores da intensidade de todos os pixels a esquerda e acima deste ponto incluindo-o. Na verdade essa representação é a composição de dois cálculos: primeiro ao longo das linhas e depois das colunas.

A utilização desta representação intermediária aumenta a velocidade de extração de características justificada pelo fato de que qualquer retângulo em uma imagem pode ser calculado pela imagem integral. São necessários apenas quatro índices da imagem integral para calcular qualquer retângulo e como consequência imediata, precisa-se de apenas uma única passagem para obter dados desejados em sub-regiões de uma imagem. Na Figura 26 há a representação de uma sub-janela que será usada no cálculo da imagem integral.



**Figura 26.** Exemplo de sub-janela para cálculo de imagem integral.


As equações (4.1) e (4.2) formalizam a imagem integral.

$$II(x, y) = \sum_{x' \leq x, y' \leq y} I(x', y'). \quad (4.1)$$

$$II(-1, y) = II(x, -1) = II(-1, -1) = 0, \quad (4.2)$$


onde  $II(x,y)$  é a Integral image e  $I(x',y')$  é a imagem original.

Dado um retângulo com suas coordenadas  $(x_1, y_1)$  e  $(x_4, y_4)$ , pode-se observar na equação (4.3) as quatro referências usadas no cálculo. Na Figura 27 é mostrado o retângulo D para cálculo da imagem integral.



**Figura 27.** Exemplo de sub-janela para cálculo de imagem integral.

Lienhart e Maydt [16] propuseram uma extensão no conceito da imagem integral permitindo o cálculo para retângulos rotacionados em  $45^\circ$ . Na equação (4.4) é formalizada a proposta e a Figura 28 ilustra a representação.



**Figura 28.** Representação de uma imagem rotacionada  $45^\circ$ .

Outra contribuição importante colocada por Lienhart e Maydt [16] é o cálculo da imagem integral quadrada, a qual é usada para a normalização às variações de iluminação devido aos tipos de características existentes em uma face. O cálculo da normalização de características utiliza valores calculados da variância da imagem. O uso da Integral Image quadrada permite maior velocidade ao cálculo como descrito na equação (4.5).

— —

## 4.4 Características

Na proposta de Viola e Jones [15] o processo de detecção de objetos é baseado na classificação de simples características. As características são baseadas nas funções básicas de Haar e foram descritas por Papageorgiou [12]. As características de Haar são simples retângulos compostos de duas regiões uma clara e outra escura. O valor da característica é a diferença entre a soma das intensidades dos pixels da região clara e a soma das intensidades dos pixels da região escura.


A escolha de características de Haar ao invés de modelos estatísticos, baseados em pontos da imagem, é justificada por Viola e Jones [15]: Pelo fato de serem de simples e rápida computação utilizando-se de imagem integral e por conterem informações de atributos imbutidos e de difícil mapeamento de forma estatística.

Viola e Jones [15] descreve 4 características básicas de Haar para uso em detecção de faces. A figura 29 mostra as características básicas de Haar usadas por Viola e Jones [15].



**Figura 29.** Características básicas de Haar.

Lienhart e Maydt [16] aprimoraram o sistema de detecção de face estendendo também o número de características. A figura 30 mostra as características propostas por Lienhart e Maydt [16].



**Figura 30.** Características Haar estendidas por Lienhart e Maydt [16].

## 4.5 Classificador Fraco

O sistema proposto por Viola e Jones [15] é montado usando-se de “classificadores fracos”. Um classificador fraco  $h_j$  é uma simples estrutura contendo um vetor de características  $f_j$ , um limiar  $\theta_j$  e uma paridade  $p_j$ . A idéia central deste classificador é encontrar um limiar que melhor separe o valor de uma característica entre imagens definidas como positivas das negativas.

A equação (4.6) formaliza a função do classificador fraco onde a paridade  $p_j$  pode assumir o valor de 1 caso os exemplos positivos sejam classificados abaixo do limiar  $\theta_j$  ou -1 se forem classificados acima deste mesmo limiar.

$$h_j(x) = \begin{cases} 1 & \text{Se } p_j f_j(x) < p_j \theta_j \\ 0 & \text{Caso Contrário} \end{cases} \quad (4.6)$$

A determinação do limiar não é objetiva e é assumido apenas que favorece o valor de menor erro de predição. Vários trabalhos propõem mecanismos para a descoberta de um bom limiar. Carboneto [13] ilustra dois métodos para encontrar este limiar, ambos baseados na distribuição de valores associados as característica dos exemplos positivos e negativos. As deficiências de não haver um limiar ótimo são compensadas pelos algoritmos de aprendizado *boosting*.

## 4.6 Algoritmo de Aprendizado

Os algoritmos de aprendizado são importantes para aprimorar a precisão de uma classificação, baseado em observações passadas. O uso de um bom algoritmo de aprendizagem proporciona uma melhor inferência na estimativa do tipo da classe do objeto em questão. Um dos problemas mais comuns em sistemas de aprendizado é a facilidade de extrair de um grande volume de dados para classificação informações relevantes para a inferência. Este é um fator limitante para performance do sistema como um todo. Uma abordagem para a minimização deste tipo de problema, baseia-se na combinação de dados fracos compondo um classificador mais forte.

Um classificador forte é composto de um conjunto de classificadores fracos associados a pesos que classificam de forma precisa dois conjuntos de imagens pré-rotuladas onde, as

características com pesos maiores são mais significativas para a classificação de exemplos definidos como parte de um certo conjunto.

Os algoritmos de aprendizagem podem ser divididos em 2 grandes grupos:

**Supervisionados** – São algoritmos de aprendizagem que a partir de um conjunto de treinamento composto de objetos de entrada e resultado desejado, prevê a classe de um objeto desconhecido

**Não-supervisionados** – São algoritmos de aprendizagem que inferem padrões e características a partir de um conjunto de entrada sem conhecimento prévio da classe do objeto.

Para cada divisão de algoritmos de aprendizagem há várias técnicas difundidas. Neste trabalho será abordado a técnicas supervisionada baseada em *Boosting* denominada *AdaBoost*.

### 4.6.1 AdaBoost

*Boosting* é um algoritmo de aprendizagem supervisionado que forma hipóteses fortes por meio de uma combinação linear de hipóteses fracas. Viola e Jones [15] representaram hipóteses fracas como classificadores fracos derivados de um conjunto de características básicas de Haar. Na equação (4.7) é formalizada a criação de um classificador forte através de um algoritmo de *Boosting*.

$$H(x) = \alpha_1 h_1 + \alpha_2 h_2 + \alpha_3 h_3 + \dots + \alpha_n h_n(x), \quad (4.7)$$

onde  $H(x)$  é um classificador forte,  $\alpha_i$  é o peso associado ao respectivo classificador fraco  $h_i$ .

AdaBoost (Adaptative Boost) foi desenvolvido por Freund e Schapire [14] e tem como característica principal a distribuição de pesos nos conjuntos de exemplos e a modificação desta distribuição com o decorrer das iterações do algoritmo. O algoritmo do AdaBoost é descrito no Algoritmo 1.

---

#### **Algoritmo 1** Pseudocódigo para AdaBoost implementado por Viola e Jones [x]

---

1. Obtém N exemplos de imagens  $(x_1, y_1), \dots, (x_n, y_n)$  onde  $x \in \mathfrak{R}$  e  $y_i = 0, 1$  para exemplos negativos e positivos respectivamente.
2. Inicializa os pesos  $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$  para  $y_i = 0, 1$  respectivamente, onde  $m$  e  $l$  são o total de exemplos negativos e positivos respectivamente.
3. Para  $t = 1, \dots, T$ :
  1. Normaliza os pesos,

$w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}$  onde  $w_t$  é uma distribuição de probabilidades

2. Para cada característica  $j$ , treine um classificador  $h_j$  restrito ao uso de apenas uma única característica. O erro é avaliado levando em conta  $w_i, e_j = W_{t,i} |h_j(x_i) - y_i|$ .
3. Escolhe um classificador  $h_t$ , com menor erro  $e_t$ .
4. Atualiza os pesos  $w_{t+1} = w_{t,i} \beta_t^{1-e_t}$ , onde  $e_i=0$  se exemplo  $x_i$  for classificado corretamente.  $e_i$  se não for e  $\beta_t = \frac{e_t}{1-e_t}$ .

4. O classificador forte é definido por:

$$h(x) = \begin{cases} 1 & \text{se } \sum_{t=1}^T \alpha_t h_t \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{caso contrario} \end{cases}, \quad \text{onde} \quad \alpha_t = \log \frac{1}{\beta_t}$$


---

Os pesos são inicializados conforme uma distribuição uniforme em seguida normalizados e por fim atualizados. A cada iteração do algoritmo os classificadores fracos vão alterando as hipóteses e a distribuição dos pesos. A alteração dos pesos é produto do peso atual por um fator  $\beta_t$ , que representa o menor erro do classificador. Caso a classificação gerada pelo classificador fraco seja correta para o conjunto de treinamento o valor do peso é reduzido.

Pode-se afirmar que o AdaBoost enfatiza classificadores ruins ou dados de difícil classificação sendo a principal característica deste algoritmo a minimização do erro sobre um conjunto de treinamento.

Após sucessivas iterações o resultado é um conjunto de hipóteses com pesos onde as que tiverem o menor erro de classificação ganham maior importância. Uma propriedade importante do AdaBoost mostrada por Freund e Schapire [14] é que o erro do treinamento tende exponencialmente a zero com o aumento da quantidade de classificadores fracos.

A propriedade mais pertinente do AdaBoost é a capacidade de redução do erro do treinamento.


## 4.7 Cascata de classificadores

Um dos grandes problemas da tarefa de classificação é o alto tempo com a exaustão do conjunto de treinamento. A redução do número de avaliações dos classificadores fracos ou até mesmo a redução da quantidade de classificadores melhoraria a velocidade do sistema, porém

...ones [15] o uso de classificadores em estrutura de árvores de decisão ou cascata de classificadores.

Viola e Jones [15] descreve a estrutura contendo um encadeamento de classificadores do mais genérico ao mais específico como uma árvore degenerativa de decisão (*decision stump*). Nos primeiros níveis da cascata não há muita precisão, apesar de conseguir classificar uma grande quantidade de amostras com uma pequena quantidade de características. Com o avanço do processo, a classificação vai se tornando mais fina e o número de características que irão ser avaliadas tende a crescer substancialmente.

A cascata caracteriza o fato de que durante a tarefa de detecção em uma imagem a maioria das janelas analisadas são rejeitadas. Isto justifica uma generalização nos primeiros estágios sendo suficiente para evitar a classificação de alvos positivos. Na figura 31 é exemplificada uma cascata de classificadores.



**Figura 31.** Exemplo de uma cascata de classificadores.

## 4.8 Treinamento da cascata de classificadores

O uso de uma cascata de classificadores provê maior velocidade na etapa de classificação, mas pode ser otimizada através da seleção inteligente dos nós das árvores de decisão. Isso é alcançado por uma abordagem focada na redução da taxa de falso positivos de cada nó melhorando a taxa de detecção. Apesar do AdaBoost conseguir uma redução significativa do erro de classificação, não é suficiente para minimizar a taxa de falso positivos do sistema. Viola e Jones [15] demonstra que dada uma árvore de classificação treinada, a taxa de falso positivos é o produto de todas as taxas de falso positivos encontrados nos nós de sua árvore, como formalizado na equação (4.9).

Viola e Jones [15] descrevem que para alcançar uma taxa de detecção de 90% é necessário apenas uma cascata com 10 estágios, onde cada estágio da cascata corresponde a um classificador fraco. Neste nível de classificador a taxa de falso positivo é de 30%. O Algoritmo 2 descreve o pseudocódigo do treinamento de uma cascata de classificadores.

---

**Algoritmo 2** Pseudocódigo do treinamento de uma cascata de classificadores

---

1. Selecciona valores para:
    1.  $f$ : o máximo valor para a aceitação da taxa de falso positivos por estágio.
    2.  $d$ : o mínimo valor de aceitação da taxa de detecção por estágio.
  2. Selecciona o valor total da taxa de falso positivos,  $F_{alvo}$ .
  3.  $P$  = conjunto de imagens positivas.
  4.  $N$  = conjunto de imagens negativas.
  5.  $F_0=1,0; D_0=1,0; i=0$ .
  6. Enquanto  $F_i > F_{alvo}$ .
    1.  $i=i+1$ .
    2.  $n_i=0; F_i=F_{i-1}$ .
    3. Enquanto  $F_i > f \times F_{i-1}$ .
      1.  $n_i = n_i + 1$ .
      2. Usa  $P$  e  $N$  para treinar com  $n_i$  características pelo AdaBoost.
      3. Avalia a atual cascata de classificadores no conjunto de validação para determinar  $F_i$  e  $D_i$ .
      4. Diminui o limiar do  $i$ -ésimo classificador até que a cascata atual tenha uma taxa de detecção pelo menos  $d \times D_{i-1}$  (afetando também  $F_i$ ).
  4.  $N=N-1$ .
  5. Se  $F_i > F_{alvo}$ , então avalie o atual detector em um conjunto de imagens negativas e coloque qualquer detecção falsa no conjunto  $N$ .
-

# Capítulo 5

## Otimização e Treinamento

Neste capítulo serão apresentados algumas definições básicas relacionadas a otimização. Serão apresentadas os principais tópicos sobre os exames de partículas e apresentado o treinamento da solução de detecção.

### 5.1 Otimização

A tarefa de otimização é determinar os melhores valores de um conjunto de parâmetros para que alguma medida de otimalidade seja satisfeita, sujeita a certas restrições. Esta tarefa é de grande importância para vários campos de atuação. As áreas exatas como: engenharia, química e informática utilizam estas estruturas quando querem obter a maximização de recursos ou minimizar os custos. Alguns dos problemas envolvem apenas modelos lineares, em que as variáveis são contínuas e apresentam comportamento linear, tanto em relação à função objetivo com às restrições, resultando em problemas de otimização linear. Outros problemas são conhecidos como problemas de otimização não-linear, onde a função objetivo ou qualquer de suas restrições possuem não-linearidade. Há dois tipos de otimização: global e local. A otimização global busca o melhor ponto dentro de todo o espaço de busca, enquanto a otimização local tenta encontrar o melhor ponto dentro de um subespaço da busca.

Na otimização local, Defini-se como ponto mínimo local  $x_B^*$ , de uma função  $f$  uma determinada região  $B$ , definida pela equação (5.1).

$$f(x_B^*) \leq f(x), \forall x \in B, \quad (5.1)$$


onde  $B \subset S \subseteq R^n$  e  $S$  é o espaço de busca.  $S = R^n$  em problemas sem restrições e  $B$  é um subconjunto de  $S$ . O espaço de busca  $S$  pode conter múltiplas regiões  $B_i$  tal que  $B_i \cap B_i =$

$\emptyset$ , quando  $i \neq j$ . O ponto mínimo de cada região  $B_i$  é único e qualquer ponto de  $x_{B_i}^*$  pode ser considerado como mínimo da região. Um algoritmo de otimização local deve garantir encontrar o mínimo local  $x_{B_i}^*$  para um conjunto  $B$ , se o ponto de partida  $x_0 \in B$ .

Na otimização global, defini-se o mínimo global  $x^*$  de uma função  $f$  definido pela equação (5.2).

$$f(x^*) \leq f(x), \forall x \in S, \quad (5.2)$$

onde  $S$  é o espaço de busca. Para problemas sem restrição o uso de  $S = R^n$ , onde  $n$  é a dimensão de  $x$ . O algoritmo de otimização global parte de um ponto inicial  $x_0 \in S$ . Na Figura 32 é mostrado o valor de um mínimo local  $x_B^*$  e do mínimo global  $x^*$  da função  $f(x) = x^4 - 12x^3 + 42x^2 - 55x$ .



**Figura 32.** Exemplo de valor mínimo local e global.

## 5.2 Otimização por enxame de partículas

Um conjunto de ferramentas bastante utilizadas para otimização de problemas são os paradigmas de computação inteligente. Segundo Engelbrecht [17], há cinco paradigmas principais de computação inteligente: Redes Neurais Artificiais, Computação Evolucionária, Inteligência de Enxames, Sistemas imunológicos Artificiais e Sistemas Fuzzy. Serão descritos os principais tópicos da técnica do paradigma de Inteligência de Enxames denominada: Otimização por Enxame de Partículas.

Otimização por Enxame de Partículas (PSO) foi proposto por Kennedy e Eberthart [18][19] e é um dos mais importantes paradigmas de inteligência de enxames. O PSO usa um mecanismo simples baseado no comportamento do vôo de pássaros e escola de peixes para guiar

partículas em busca de uma solução ótima global. O PSO é baseado em um método estocástico e não se utiliza de gradientes. Sua implementação é bastante simples e é aplicado na resolução de problemas otimização assim como os Algoritmos Genéticos.

### 5.2.1 Funcionamento do PSO

O algoritmo do PSO é baseado em uma população de partículas, onde cada partícula representa uma possível solução do problema em questão. Cada partícula  $p$  pode ser representada como um objeto com várias características. Destacam-se as seguintes características:

- $x_p$ : A posição atual da partícula;
- $v_p$ : A velocidade atual da partícula;
- $y_p$ : A melhor posição individual da partícula.

A posição da partícula é ajustada de acordo com sua própria experiência e da experiência de sua vizinhança.  $x_p(t)$  representa a posição da partícula  $p$  no espaço de busca num instante  $t$ . A melhor posição individual da partícula  $p$  representa a melhor posição em que a partícula esteve e onde obteve a melhor avaliação. Como exemplo, numa tarefa de uma minimização, a posição de uma partícula  $p$  que obteve o menor valor da função é considerada como sendo a posição com melhor avaliação ou com mais alta aptidão. Na equação (5.3) é denotada a função de atualização da melhor posição individual de uma partícula utilizando o tempo  $t$  explicitamente.

$$y_p(t+1) = \begin{cases} y_p(t) & \text{se } f(y_p(t)) \leq f(x_p(t+1)) \\ x_p(t+1) & \text{se } f(y_p(t)) > f(x_p(t+1)) \end{cases}, \quad (5.3)$$

onde  $f$  representa a função objetivo que está sendo minimizada.

O algoritmo do PSO faz uso de duas sequências aleatórias independentes,  $r_1 \sim U(0,1)$  e  $r_2 \sim U(0,1)$ . Estas sequencias são usadas para dar a natureza estocástica ao algoritmo. Essas sequências são utilizadas para a atualização da velocidade da partícula  $v_p$  demonstrada na equação (5.4).

$$v_{p,j}(t+1) = v_{p,j}(t) + c_1 r_{1,j}(t)[y_{p,j}(t) - x_{p,j}(t)] + c_2 r_2(t)[b_j(t) - x_{p,j}(t)], \quad (5.4)$$

onde,  $b$  é a posição da melhor partícula do enxame no momento, os valores de  $r_1$  e  $r_2$  são escalados através de constantes  $c_1 > 0$  e  $c_2 \leq 2$ . Estas constantes são chamadas de coeficientes

de aceleração e exercem influência no tamanho máximo do passo de que uma partícula pode dar em uma única iteração. A velocidade que atualiza o passo é especificada separadamente para cada dimensão  $j \in 1 \dots n$ , de forma que  $v_{p,j}$  denota a dimensão  $j$  do vetor de velocidade associado com a partícula  $p$ .

Na definição da equação da atualização da velocidade, a constante  $c_2$  regula de uma forma clara o tamanho máximo do passo na direção da melhor partícula global sendo denominada de coeficiente social. Já a constante  $c_1$  regula o tamanho do passo na direção da melhor posição individual de cada partícula sendo denominada de coeficiente de cognição. O valor de  $v_{p,j}$  é mantido dentro do intervalo de  $[-v_{max}, v_{max}]$ , reduzindo a probabilidade de que uma partícula saia fora do espaço de busca. Se o espaço de busca for definido pelo intervalo  $[-x_{max}, x_{max}]$ , então o valor de  $v_{max}$  é calculado como na equação (5.5).

$$v_{max} = kx_{max}, \quad (5.5)$$

onde  $0,1 \leq k < 1,0$ .

A posição de cada partícula é atualizada usando o seu novo vetor de velocidade, como descrito na função (5.6). O Algoritmo 3 descreve o pseudocódigo do algoritmo básico do PSO.

$$x_p(t + 1) = x_p(t) + v_p(t + 1). \quad (5.6)$$

---

**Algoritmo 3** Pseudocódigo do algoritmo do PSO básico

---

1. Inicializa uma população com  $n$  partículas.
  2. Enquanto número máximo de iterações ou fitness desejado não for alcançado.
    1. Calcula o fitness para cada partícula  $p$ .
    2. Atualiza a posição de cada partícula  $p$  e se o fitness atual for melhor que o anterior atualiza a melhor posição da partícula pela posição atual.
  3. Para cada partícula  $p$ .
    1. Calcula  $v_p$  de acordo com a equação. (5.4)
    2. Atualiza  $x_p$  de acordo com a equação. (5.6)
    3. Atualiza a posição da melhor partícula do enxame.
- 

A inicialização do algoritmo consiste em inicializar cada coordenda  $x_{p,j}$  com um valor aleatório do intervalo  $[-x_{max}, x_{max}]$ , para todo  $p$  e  $j \in 1 \dots n$ . Isto distribui as posições iniciais das partículas ao longo do espaço de busca. A inicialização de cada  $v_{p,j}$  deve ser feita com um valor extraído do intervalo  $[-v_{max}, v_{max}]$ , para todo o  $p$  e  $j \in 1 \dots n$ . As velocidades das partículas podem ser iniciadas com o valor 0 (zero).

A condição de parada do algoritmo depende do tipo de problema. Normalmente o algoritmo é executado com um número pré-determinado de iterações ou até alcançar um valor específico de erro. Uma breve descrição do funcionamento do PSO é descrita a seguir:

Inicialmente uma partícula qualquer é identificada como sendo a melhor partícula no grupo, baseado na sua aptidão usando-se a função objetiva. Então todas as partículas serão aceleradas na direção desta partícula, e ao mesmo tempo na direção das próprias melhores posições previamente encontradas. Ocasionalmente as partículas exploram o espaço de busca ao redor da atual melhor partícula. Desta forma, todas as partículas terão a oportunidade para mudar a sua direção e buscar uma nova melhor partícula. Considerando que a maioria das funções têm uma forma de continuidade, as chances de encontrar uma das melhores soluções, no espaço de busca no sentido da melhor solução, são promissoras próximo da melhor partícula.

O PSO possui duas modelagens o melhor global e o melhor local, respectivamente *gbest* e *lbest*.

No modelo *gbest* mantém apenas uma única melhor solução, denominada de melhor partícula global (*gbest*) em todas as partículas do enxame. Esta partícula age como um atrator, puxando as partículas para próximo de si. Como consequência, é provável que todas as partículas convergirão para a posição da partícula *gbest*, sendo uma convergência prematura caso não haja uma atualização constante do *gbest*.

O modelo *lbest* tenta prevenir a convergência prematura mantendo múltiplos atratores. Um subconjunto de partículas é definido para cada partícula de onde é selecionada a melhor partícula de cada subconjunto.

## 5.2.2 Principais propostas de melhorias

Vários estudos foram desenvolvidos a cerca do algoritmo básico do PSO e novas propostas são divulgadas com o objetivo de prover maior performance a técnica. Destacam-se as principais colaborações:

**Peso de inércia** – proposto por Shi e Eberhart [20] foi uma das primeiras modificações visando melhorar a taxa de convergência. O peso de inércia é um fator escalar associado com a velocidade descrito na equação (5.7).

$$v_{p,j}(t + 1) = wv_{p,j}(t) + c_1r_{1,j}(t)[y_{p,j}(t) - x_{p,j}(t)] + c_2r_2(t)[b_j(t) - x_{p,j}(t)], \quad (5.7)$$

Shi e Eberhart [20] investigaram os efeitos dos valores de  $w$  e demonstraram que  $w \in [0,8, 1,2]$  resulta em uma convergência mais rápida.

**Coefficiente de enxugamento** – Proposto por Clerc [21], demonstra que o coeficiente de enxugamento pode ajudar a garantir a convergência. O coeficiente de enxugamento descreve um modo de seleção dos valores de  $w$ ,  $c_1$  e  $c_2$  de forma a garantir a convergência. A equação (5.8) descreve a proposta do coeficiente de enxugamento.

$$v_{p,j}(t+1) = X(v_{p,j}(t) + c_1 r_{1,j}(t)[y_{p,j}(t) - x_{p,j}(t)] + c_2 r_{2,j}(t)[b_j(t) - x_{p,j}(t)]), \quad (5.7)$$

$$\text{onde, } X = \frac{2}{|2-\varphi-\sqrt{\varphi^2-4\varphi}|}, \quad \text{e } \varphi = c_1 + c_2, \quad \varphi > 4.$$

Várias propostas focando alterações na topologia do PSO também foram como por exemplo o Clan PSO proposto por Carvalho e Bastos-Filho [22] que subdivide o enxame em clans e dinamicamente altera a topologia em função do sucesso de cada clan. Outra abordagem é o Multi-Ring PSO proposto por Carvalho, Caraciolo, Miranda e Carvalho [23] que propõem uma topologia em multi-anéis focando na diversidade provida pela rotação dos anéis. Com o objetivo de promover auto-adaptação Zhan, Zhang, Li e Chung [24] propõem o Adaptive Particle Swarm Optimization, onde através de um estágio de evolução identifica qual deve ser a melhor configuração dos parâmetros.

# Capítulo 6


## Modelo Proposto

Neste capítulo será apresentado o modelo proposto por este trabalho. A proposta de trabalho descreve as etapas seguidas enquanto que os arranjos experimentais descreve as atividades e os resultados obtidos em cada etapa.

### 6.1 Proposta de trabalho

Com o aumento da esquistossomose no litoral pernambucano investigado por Constança [3][4][5], a necessidade de uma rápida identificação dos infectados é um dos fatores primordiais para o controle da epidemia. Através de uma parceria entre o grupo de pesquisa Xiscanoé [25], o Laboratório de Esquistossomose do Departamento de Parasitologia da CpqAM/FIOCRUZ e o Departamento de Sistemas e Computação da Universidade de Pernambuco, foi possível mapear o método de diagnóstico para a esquistossomose e propor um sistema para sua automatização.

A proposta deste trabalho consiste em desenvolver uma solução para a contagem automatizada dos ovos de *S. mansoni* nos exames parasitológicos de fezes dos indivíduos suspeitos. A solução proposta está dividida em 3(três) fases distintas: Na primeira fase a aquisição das imagens da lâmina do exame parasitológico de fezes dos indivíduos suspeitos e pré-processamento, na segunda fase o desenvolvimento de um sistema que identifique e detecte o ovo de *S. mansoni* nas imagens geradas a partir da primeira fase e na terceira fase a utilização de um PSO para otimizar o treinamento do sistema desenvolvido na segunda fase. Na figura 33 há um fluxograma da solução proposta por cada fase.



**Figura 33.** Fluxograma por fase da solução.

## 6.2 Arranjos Experimentais

Nesta seção será detalhado o desenvolvimento das tarefas em cada fase da solução proposta.

### 6.2.1 1ª Fase – Captura e pré-processamento de imagem.

Na primeira fase da solução proposta o grande desafio é a captura da imagem da lâmina do exame parasitológico de fezes de um indivíduo infectado. A realiação desta fase pode ser descrita em três atividades principais: A Seleção do equipamento de captura de imagens, o acoplamento do equipamento selecionado ao microscópio e o pré-processamento das imagens capturadas. Foram utilizados os seguintes requisitos para implementação desta fase:

1. Seleção de um equipamento com característica de captura de imagem contínua.
2. Resolução mínima de captura de imagem de 352 x 288 pixels.
3. Taxa de captura de vídeo de 30 FPS (Frames Por Segundo).
4. Conectividade USB para interligação ao PC.
5. Baixo custo de aquisição (valor nominal inferior a R\$ 100,00).
6. Acesso aos principais recursos do equipamento através de drivers de comando no Sistema Operacional do PC.

#### **Atividade 1** – Seleção do equipamento de captura de imagens.

Inicialmente foram analisados 3(três) tipos de equipamentos: uma placa de captura de imagens com conexão USB interligando uma câmera de vídeo AV com sensor CCD preto e branco, uma webcam com sensor CMOS de 300K pixels de resolução e uma câmera fotográfica digital com sensor CCD de 8M pixels de resolução. De acordo com o requisito 5 não foi possível

a utilização do equipamento 3 a câmera fotográfica digital por necessitar de intervenção humana no hardware para aquisição das imagens, ou seja, o sistema não teria controle sobre a aquisição das imagens.

Com o descarte do equipamento 3, câmera fotográfica digital, foram analisados os seguintes equipamentos: Placa de captura de imagens Easycap USB com resolução de 720 x 480 pixels, interligando uma micro-câmera de vídeo AV Sony com sensor CCD preto e branco e uma Webcam Trust USB com sensor CMOS de 300K pixel de resolução, exibidos na Figura 34.



**Figura 34.** 1-Easycap, 2- câmera Sony, 3- Fonte de alimentação e 4 – Webcam Trust.

Inicialmente foram utilizadas duas abordagens para os testes com os equipamentos: Interligação dos equipamentos ao microscópio utilizando a justaposição das lentes ou o foco direto no sensor dos equipamentos.


Na abordagem de justaposição de lentes, a câmera em questão era acoplada diretamente na lente objetiva do microscópio. Já na abordagem de foco direto no sensor, a lente da câmera foi removida e realizado o acoplamento entre o sensor e a lente objetiva do microscópio. Em ambos os casos na fixação dos equipamentos ao microscópio foi utilizado fita isolante de baixa tensão. Como consequência direta da utilização de cada abordagem temos as seguintes observações descritas na Tabela 1.

**Tabela 1** – Comparativo entre justaposição de lentes e foco direto no sensor.

Características	Justaposição de lentes	Foco direto no sensor
Tamanho da imagem.	Real, como percebido pelo olho humano.	Ampliada e restrita ao tamanho correspondente a área do sensor.
Foco	Ajustável através da câmera e do microscópio.	Fixo na câmera e ajustado pelo microscópio.
Intervenção no Hardware	Nenhuma.	Remoção da lente.

Região de sombra na imagem	Borda circular escura	Nenhuma.
----------------------------	-----------------------	----------

Com base nas observações da Tabela 1 foi definido a abordagem de justaposição de lentes como melhor estratégia. Na Figura 35 (A) é mostrada uma imagem adquirida pela câmera Sony e a placa Easecap com foco direto no sensor. NA Figura 35 (B) é mostrada uma imagem adquirida pela webcam trust com foco direto no sensor. Na Figura 36 é mostrada uma imagem adquirida pela câmera fotográfica digital usando justaposição de lentes.



**Figura 35.** Imagem capturada pela placa Easecap e câmera Sony.



**Figura 36.** Imagem da objetiva do microscópio usando justaposição de lentes.


A partir de uma análise das imagens obtidas pela câmera Sony usando a placa Easecap, foi detectado que há ruídos como linhas horizontais caracterizando interferências eletromagnéticas possivelmente provenientes de alimentação elétrica. Na Figura 35 (A) pode ser visto como linhas horizontais as regiões com maior luminosidade. Levando em consideração também a necessidade de uma placa de captura como a Easecap e uma fonte de alimentação independente, além de não

capturar imagens coloridas, Foi eleita a webcam como equipamento de captura de imagens que atendem a todos os requisitos estabelecidos.

Devida a baixa resolução do sensor CMOS da webcam trust, foi eleita a webcam vtrex modelo x16000 com um sensor CMOS de segunda geração com resolução de 2M pixels. Na Figura 37 é mostrada a webcam vtrex e na Figura 38 um comparativo entre a imagens das webcasns trust e vtrex utilizando justaposição de lentes.



**Figura 37.** Webcam vtrex modelo x16000.



**Figura 38.** (A) Imagem da capturada pela webcam vtrex, (B) imagem capturada pela webcam trust.


É possível perceber a diferença de qualidade das imagens capturadas pelas duas webcams utilizadas. Destacam-se a maior fidelidade de cores e melhor definição das imagens capturadas pela webcam vtrex.

**Atividade 2** – *Sistema de fixação da webcam ao microscópio.*

Após a definição do equipamento de captura de imagens é necessário um sistema de fixação à lente ocular do microscópio. Os requisitos para essa atividade são:


1. Preservar a integridade do microscópio sem alterar ou danificá-lo.
2. Ser um sistema de fixação ajustável.
3. Ser um sistema de fixação de baixo custo.

Visando o cumprimento dos requisitos, a idéia principal para o sistema de fixação partil da observação da lente ocular do microscópio utilizado. A Figura 39 ilustra as dimensões da lente ocular do microscópio utilizado.



**Figura 39.** Ilustração da lente ocular do microscópio com vista frontal e superior.

Com as dimensões da ocular foi realizada uma busca por alguma peça pré-moldada que pudesse ser utilizada como base do sistema de fixação. Foi utilizado uma peça de redução hidráulica de 20 x 40 mm, onde envolveria a ocular do microscópio e serviria para acoplar a webcam. Foi necessário realizar um corte de para a retirada de 8 mm da peça e realizado o lixamento para melhor aderência da lente da webcam. A Figura 40 mostra a criação da peça em 3 etapas.



**Figura 40.** (A) Peça original, (B) Peça com corte de 8 mm e (C) Peça concluída.

Após o corte e lixagem da peça, foram feitos 4 furos e colocados 4 parafusos para que seja feita a fixação da peça na ocular do microscópio. Para a fixação da webcam, foi cuidadosamente

lixada a parte superior da peça para se encaixar hermeticamente com o regulador de foco da webcam. Para a realização do trabalho na peça foi utilizada uma mini retífica sem o uso de cola ou adesivo. Para finalizar a peça foi dado um acabamento pintando-a da cor preta. Na Figura 41 é mostrada a peça final acoplada a webcam.



**Figura 41.** vista frontal (A) e lateral (B) da webcam e adaptador.

### **Atividade 3 – Pré-processamento das imagens.**

Com a fase de captura concluída e funcional, é necessário definir quais os recursos de pré-processamento deverão ser aplicados as imagens capturadas. Essa atividade é apenas para a definição das técnicas que serão implementadas na fase seguinte. Segundo Viola e Jones [15], a primeira técnica utilizada será a conversão da imagem colorida para Grayscale. O uso da imagem em Grayscale proporciona uma maior velocidade no processamento e menor uso de recursos computacionais. Após a conversão da imagem, foi aplicado uma equalização por histograma para configurar adequadamente o contraste e realçar informações que antes estavam perdidas. Por fim foi aplicado um detector de borda baseado no algoritmo de Canny. O algoritmo de Canny é tipo como o algoritmo ótimo para detecção de bordas, baseado em um operador gaussiano de primeira derivada além de suavizar os ruídos na imagem.

## **6.2.2 2ª Fase - Desenvolvimento do sistema de detecção de ovos de *S. mansoni***



## Conclusões e Trabalhos Futuros

Considerando-se o exposto pelo presente trabalho, concluímos que as redes *ad hoc* sem fio estão na vanguarda da tecnologia envolvendo nós móveis, de modo que as aplicações e uso deste tipo de rede torna-se cada vez mais premente. Em função disto, os modelos de mobilidade que simulam o uso destas redes têm um grau de importância elevado, sendo responsáveis pela avaliação de protocolos e, portanto, seu funcionamento deve procurar retratar a realidade. Para que isto aconteça ressaltamos que a escolha dos parâmetros são importantes no intuito de apresentar dados diferentes que variam em função do cenário adotado.

Desta forma e levando em conta a análise realizada, destacamos que o *Random Waypoint* (modelo de mobilidade mais difundido) apresenta uma limitação grave que leva a rede a estagnação quando a velocidade mínima para escolha de velocidades dos nós é nula [15]. Posto isto, foram executadas ações no intuito de demonstrar que esta limitação pode ser corrigida através de uma implementação eficiente que atua diretamente na escolha da velocidade de deslocamento dos nós da rede em avaliação, modelando-a através de uma função de distribuição de probabilidade BETA(2,2) [16], [22].

A partir dos resultados obtidos em [16] e [18], esta dissertação desenvolveu um modelo matemático que representa o comportamento da velocidade média dos nós em redes *ad hoc* sem fio para o *Random Waypoint* empregando uma distribuição genérica BETA( $\alpha, \beta$ ). Ou seja, o presente trabalho generalizou os resultados observados em [15], [16], [18] e [22], indicando quais valores de  $\alpha$  e  $\beta$  levam o *Random Waypoint* à estabilização ou não no que se refere à velocidade média instantânea dos nós e que tem impacto direto sobre as medidas de desempenho de protocolos de comunicação. Os resultados analíticos para velocidade foram confirmados por simulações em C++.

Foram também apresentados resultados de simulações realizadas em NS-2 que mostram que medidas de desempenho de protocolos de comunicação são estabilizadas para o *Random Waypoint* cuja escolha de velocidade de deslocamento dos nós é realizada a partir da distribuição BETA(2,1). Além disso, a partir dos resultados observados em [15], [16], [22] pode-se concluir

que estabilizando a velocidade média instantânea dos nós, estabiliza-se as medidas de desempenho.

Como principais metas alcançadas listamos os seguintes itens:

- Análise abrangente do problema detectado no modelo de mobilidade *Random Waypoint*;
- Estudo sobre comportamento de redes *ad hoc* sem fio que utilizam o *Random Waypoint*;
- Aplicação da distribuição de probabilidade BETA ( $\alpha, \beta$ ) para escolha da velocidade de deslocamento dos nós em simulações usando o *Random Waypoint*;
- Desenvolvimento matemático para obtenção de modelo que represente de forma genérica o comportamento da velocidade média instantânea dos nós durante as simulações. Pode-se verificar também o comportamento da velocidade de deslocamento dos nós (Equação 37) quando se modifica os parâmetros  $\alpha$  e  $\beta$  da distribuição BETA ( $\alpha, \beta$ ). Estas alterações podem envolver relações matemáticas específicas (Ex.:  $\alpha - \beta = 3$ ) ou genéricas ( $\alpha = n$  e  $\beta = n - 1$ ), conforme mostrado na Tabela 1.
- Execução de simulações com aplicação direta do modelo alcançado e apresentação mais específica de dois casos de simulação (contribuição dos pesquisadores Alisson S. L. Pontes e Fagner P. Araújo);
- Demonstração analítica de estabilização de redes *ad hoc* sem fio quando usando o *Random Waypoint* e uma função densidade de probabilidade aplicada ao tempo de viagem do nó que influencia preponderantemente a velocidade média de deslocamento dos nós para que a mesma não assuma valor nulo ou deacimento gradual durante o tempo de simulação;
- Constatação de simples implementações dos resultados obtidos que podem ser executadas diretamente a partir dos simuladores existentes, tais como NS-2 [11] e JiST/SWANS [12];
- Apresentação de resultados práticos a partir do uso da distribuição BETA(2,1) para escolha da velocidade de deslocamento dos nós para consecução da estabilização do modelo de mobilidade *Random Waypoint*. Isto resultou na publicação do artigo "Estabilizando o Modelo *Random Waypoint* através da Função BETA(2,1) para Escolha da Velocidade dos Nós em Redes *Ad Hoc* sem Fio" no *8th International Information and Telecommunication Technologies Symposium*, realizado de 09 a 11 de dezembro de 2009 em Florianópolis, SC.

Diante do descrito anteriormente e levando-se em conta os resultados, verifica-se como possibilidade real de trabalhos futuros, a avaliação de outras distribuições de probabilidade para escolha da velocidade dos nós e sua consequência sobre o desempenho de protocolos de comunicação em redes *ad hoc* sem fio.

Este trabalho utilizou o AODV como protocolo para avaliação de desempenho. É possível também se usar outros protocolos de roteamento como o DSR, que foi empregado em [15] levando a resultados similares ao AODV.

Por fim, conforme já explicado, a idéia do trabalho desenvolvido não é criar um novo modelo de mobilidade, mas sim corrigir a limitação existente no *Random Waypoint*, de modo que o mesmo possa ser usado sem restrições quanto à problemas de estabilização da velocidade média dos nós e das medidas de desempenho.

# Bibliografia

- [1] N. Katz., S. V. Peixoto., “Análise crítica da estimativa do número de portadores de esquistossomose mansoni no Brasil” Revista da Sociedade Brasileira de Medicina Tropical, 2000.
- [2] P.H. Kano, “Measures for Control of Schistosomiasis Adapted by the Fundação Nacional de Saúde.” Memórias do Instituto Oswaldo Cruz, 87 (Sup. IV), 315-318. 1992.
- [3] C. S. Barbosa, J. F. Gonçalves, Y. Albuquerque, F. S. Barbosa. “Urban Schistosomiasis im Itamaracá island, Brasil, epidemiological factors 66 involved in the recent endemic process.” Memórias do Instituto Oswaldo Cruz, 93 (01), 265-266, 1998.
- [4] C. S. Barbosa, O. S. Pieri, “Aspectos epidemiológicos e malacológicos da esquistossomose mansônica na Ilha de Itamaracá, Pernambuco.” Revista de Saúde Pública,34(4), 33-41, 2000.
- [5] C. S. Barbosa, A. L. Coutinho, S. M. L. Montenegro, F. Abath, V. Spinelli. “Epidemia de esquistossomose aguda na praia de Porto de Galinhas, Pernambuco.” Cadernos de Saúde Pública, 17(3), 725-728, 2001.
- [6] N. Katz., G. Chaia, “Coprological diagnosis of Schistosomiasis. I. Evaluation of quantitative technique”. Rev. Inst. Med. trop. S. Paulo, 10:295-8, 1968.
- [7] O. dos S. Carvalho, P. M. Z. Coelho, H. L. Lenzi, "Schistosoma mansoni e esquistossomose, uma visão multidisciplinar".. Rio de Janeiro, Editora Fundação Oswaldo Cruz, 2007, v. 1, p. -.
- [8] A. L. T. Rabello, “Novas abordagens para o diagnóstico da esquistossomose mansoni humana aguda e crônica”.
- [9] R. C. Gonzalez, R. E. Woods, Processamento de Imagens Digitais. Trad.: Roberto M. C. Júnior e Luciano F. Costa. Edgard Blücher, São Paulo (2003)
- [10] T. Acharya, A. K. Ray, “ Image Processing principles and applications”, John Wiley & Sons, Inc, 2005.
- [11] G.Bradski, A. Kaebler; Learning OpenCV – Computer Vision with the openCV Library, O’Reilly, Setember 2008.

- [12] C. P. Papageorgiou, M. Oren, T. Poggio. A general framework for object detection. In ICCV '98: Proceedings of the Sixth International Conference on Computer Vision, page 555, Washington, DC, USA, 1998. IEEE Computer Society.
- [13] P. Carbonetto, Robust object detection using boosted learning, 2002.
- [14] Freund Y. and Schapire R. E., A Short Introduction to Boosting, Journal of Japanese Society for Artificial Intelligence, 14(5), September 1999. 771-780.
- [15] P. Viola, M. J. Jones, Robust real-time face detection. Int. J. Comput. Vision, 57(2):137–154, 2004.
- [16] R. Lienhart, J. Maydt, An Extended Set of Harr-like Features for Rapid Object Detection. Technical report, Microprocessor Research Lab, Intel Labs, December 2002.
- [17] A. P. Engelgrecht, Computational Intelligence an Introduction Second Edition, Jhon Wiley & Sons, LTD, 2007.
- [18] J. Kennedy, R. C. Eberhart, “Particle swarm optimization,” in Proc. of the IEEE Int. Conf. on Neural Networks. Piscataway, NJ, IEEE Service Center, 1995, pp. 1942–1948.
- [19] R. C. Eberhart and J. Kennedy, “A new optimizer using particle swarm theory,” in Proc. 6th Int. Symp. Micromachine Human Sci., Nagoya, Japan, 1995, pp. 39–43.
- [20] Y. Shi and R. Eberhart, “A Modified Particle Swarm Optimizer,” Proceedings of the 1998 IEEE Congress on Evolutionary Computation, Anchorage, AK, pp. 69-73.
- [21] M. Clerc, “The swarm and the queen: Toward a deterministic and adaptive particle swarm optimization,” in Proc. IEEE Congr. Evol. Comput., 1999, pp. 1951–1957.
- [22] D.F. Carvalho, C.J.A. Bastos-Filho, “Clan Particle Swarm Optimization,” IEEE Congress on Evolutionary Computation, 2008, pp. 3044 - 3051, 1999.
- [23] C. J. A. Bastos-Filho, M. P. Caraciolo, P. B. C. Miranda, D. F. Carvalho, “Multi-Ring Particle Swarm Optimization,”
- [24] Z.H. Zhan, J. Zhang, Y. Li, H. S.H. Chung, “Adaptive Particle Swarm Optimization,” IEEE transactions on systems, man, and cybernetics—part b, cybernetics, April 2009.
- [25] Web site do grupo de pesquisa Xiscanoé, <http://200.17.137.109:8081/xiscanoé> - com último acesso em 10/07/2010.
- [26] G. V. Nosovski, L. Dongquan, O. Sourina, “Automatic clustering and boundary detection algorithm based on adaptive influence function,” Pattern Recognition, Volume 41, Issue 9, pp. 2757-2776, September 2008.
- [27] Omran, M. G. H. Particle Swarm Optimization Methods for Pattern Recognition and Image Processing. PhD Thesis. University of Pretoria, Pretoria, November (2004)

- [28] Omram, M. G. H.; Salman, Ayed and Engelbrecht, A. P. Dynamic clustering using particle swarm optimization with application in image segmentation. *Pattern Anal App*, vol 8, pp. 332–344 (2006)
- [29] Pham, D. L.; Xu, C. and Prince, J. L. A Survey of Current Methods in Medical Image Segmentation. The Johns Hopkins University, Baltimore, *Annual Review of Biomedical Engineering*, January (1998)
- [30] J. G. Souza, J. A. F. Costa; Particle Swarm Optimization e Fuzzy Clustering em Segmentação de Imagens Médicas. UFRN – CT – PPgEE.MELLO, C.A.B. *Synthesis of Images of Historical Documents for Web Visualization*, Proceedings of IEEE International Multi-Media Modelling Conference, 2004, Brisbane, AU.