

Reconhecimento de Padrões em Imagens de Triatomíneos Usando Redes Neurais Artificiais com Algoritmo Backpropagation

Joao Marcelino Pacheco Neto
Universidade Federal do Pará - Nucleo de
Desenvolvimento Amazônico em Engenharia
Tucuruí, Pará, Brasil
joamarcelino110@gmail.com

Otavio Noura Teixeira
Universidade Federal do Pará - Nucleo de
Desenvolvimento Amazônico em Engenharia
Tucuruí, Pará, Brasil
onoura@gmail.com

ABSTRACT

Chagas disease, also known as American trypanosomiasis is one of the consequences of the human infection caused by the flagellate protozoan called *Trypanosoma cruzi* transmitted by the barbeiro of the subfamily *Triatominae* known as triatomines. In the Lower Tocantins region of the state of Para, three genera of barbers transmitting the disease are found. Searching for a way to automate the manual recognition process, this work aimed to implement a Model of Recognition and Classification of Images of barbers found in the Lower Tocantins region in order to recognize the genus of the insect through the use of Artificial Neural Networks Perceptron Multi-layered and performing training with Backpropagation algorithm, helping to identify the transmitters. In the middle of this recognition, the Digital Image Processing is performed to extract important characteristics relevant to the classification. This entire process is performed in MATLAB software through scripts and the creation of the Artificial Neural Network in the toolbox called Pattern Recognition App.

KEYWORDS

Doença de Chagas, Reconhecimento de Imagem, Classificação de Padrões, Redes Neurais Artificiais, Processamento Digital de Imagem

1 INTRODUÇÃO

A doença de chagas foi descrita pela primeira vez em 1908-1909 pelo médico epidemiologista Carlos Chagas e possui duas fases no indivíduo humano podendo ter consequências graves sem tratamento, levando até a morte. *Triatominae* é uma subfamília da família *Reduviidae* onde várias espécies atuam como transmissores da doença de chagas.

Atualmente existem cerca de 140 espécies de triatomíneos, subdividido em 14 gêneros, no Brasil são 61 espécies presentes, a maioria é encontrada em ambientes silvestres. Na região do baixo Tocantins são encontradas poucas espécies sendo de três gêneros que podem ser transmissoras da doença e que são identificadas de forma manual.

Visando o reconhecimento dessas espécies, surgiu a ideia de realizar o Reconhecimento de Imagens e utilizar Redes Neurais junto com o Processamento Digital de Imagem para distinguir os insetos vetores da doença identificando seu gênero pertencente.

Em [1] buscou-se apresentar uma pesquisa baseada na viabilidade de classificação de insetos através de imagens 2D avaliando as variáveis do ambiente além de mensurar suas possíveis dificuldades baseando-se em 44 artigos. [2] apresenta uma metodologia de processamento de imagens combinado com Redes Neurais *feed-forward* para identificação de pragas mais agressivas na agricultura além de um trabalho de testes sobre 16 possíveis configurações da rede até a classificação dos insetos.

E [3] utiliza de imagens de crânio para classificação de espécies de animais recorrentes da Malásia Peninsular. Sua classificação utiliza da variação de posição do crânio (visão dorsal, lateral e mandibular) para segmentação e extração das características da imagem e utilizou de rede neural artificial no software MATLAB, apresentando uma taxa de precisão boa em suas conclusões.

Foi realizado o reconhecimento de padrões de imagens de barbeiros utilizando Redes Neurais *Perceptron* Multicamadas, com treinamento supervisionado e algoritmo de retro propagação (*backpropagation*).

Nas imagens exemplo dos insetos foram realizados processamentos de imagens para eliminar as imperfeições, separar e descartar informações desnecessárias utilizando métodos como histograma e filtros passa baixa e passa alta. Para toda a experiência foi utilizado o software MATLAB através de suas ferramentas.

2 DOENÇA DE CHAGAS

Estima-se que cerca de 8 milhões de pessoas em todo o mundo, principalmente na América latina estejam contaminados com o protozoário causador da doença de chagas [4]. É uma doença que se manifesta de duas formas, pela fase crônica podendo comprometer órgãos, onde 30% dos pacientes sofrem de distúrbios cardíacos e 10% sofrem de distúrbios digestivos (tipicamente aumento do esôfago ou do cólon) ou pela fase aguda com sintomas ou assintomática se agravando assim, para a fase crônica.

O círculo de transmissão vetorial inicia-se com a defecação do vetor no momento da picada e a penetração do parasita através desse orifício por continuidade no ato de coçar, então os parasitas entram nas células próximas ao incidente, caem na corrente sanguínea se replicam infectando novas células. A partir desse ponto o hospedeiro vetor suga esse sangue

Tabela 1: Gêneros e Espécies de Triatomíneos Registrados no Brasil

Gêneros	Espécies
<i>Panstrongylus</i>	<i>Panstrongylus geniculatus</i>
<i>Panstrongylus</i>	<i>P. lignarius</i>
<i>Panstrongylus</i>	<i>P. megistus</i>
<i>Panstrongylus</i>	<i>P. rufotuberculatus</i>
<i>Rhodnius</i>	<i>Rhodnius milesi</i>
<i>Rhodnius</i>	<i>R. paraenses</i>
<i>Rhodnius</i>	<i>R. pictipes</i>
<i>Rhodnius</i>	<i>R. robustus</i>
<i>Triatoma</i>	<i>Triatoma rubrofasciata</i>
<i>Eratyrus</i>	<i>Eratyrus mucronatus</i>
<i>Cavernicola</i>	<i>Cavernicola pilosa</i>
<i>Alberprosenia</i>	<i>Alberprosenia malheroi</i>
<i>Belminus</i>	<i>Belminus laportei</i>
<i>Microtriatoma</i>	<i>Microtriatoma trinidadensis</i>

se infectando com o parasita flagelado e se hospedando no intestino do vetor [5].

2.1 Triatomíneos

Os vetores da doença de Chagas são da classe *Hemiptera*, família *Reduviidae* e subfamília *Triatominae* [6]. Apresentam o primeiro par de asas com uma parte membranosa e outra parte dura, também possuem o aparelho bucal picador-sugador e se alimentam de outros insetos e de sangue de vertebrados.

Essa subfamília divide-se em cinco tribos, incluindo 18 gêneros e 148 espécies. A maioria delas encontram-se em regiões tropicais como a América do sul, mas também podem ser encontradas nos Estados Unidos, África, Ásia e norte da Austrália. No Brasil, foram registradas até o momento 64 espécies [7], destas 64 espécies, 15 são encontradas no Pará.

A região do baixo Tocantins no Pará é composta de 11 municípios possuindo uma área territorial de quase 36 mil quilômetros quadrados. Nessa região são encontrados apenas três gêneros dos insetos: os *Panstrongylus*, *Rhodnius* e *Eratyrus*. Esse foi o foco da pesquisa nesse trabalho, visando expansão em um futuro próximo.

Os triatomíneos, como todos os insetos, possuem o corpo dividido em três regiões: cabeça, tórax e abdômen [8]. São insetos grandes, medindo 1 a 4 cm de comprimento. Um ponto que ajuda a distinguir os gêneros é a cabeça desses indivíduos. Nas antenas há uma peça chamada de tubérculo antenífero, que é de grande valia na identificação de alguns gêneros da espécie por serem espécies frequentemente encontradas em domicílios.

Nos três gêneros encontrados na região, nos *Panstrongylus* as antenas encontram-se inseridas junto à margem anterior dos olhos, nos *Rhodnius* as mesmas apresentam-se no ápice da cabeça e nos *Eratyrus* as antenas inserem-se na metade da distância entre o ápice da cabeça e a margem anterior dos

olhos [9]. Na fig. 1 está exemplificado a diferença entre os insetos.

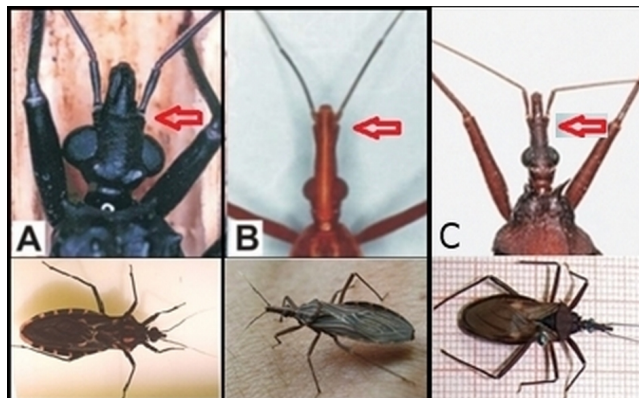


Figura 1: Diferenciação dos gêneros. (A) *Panstrongylus* as antenas encontram-se inseridas junto à margem anterior dos olhos; (B) *Rhodnius* as antenas apresentam-se no ápice da cabeça; (C) *Eratyrus* as antenas inserem-se na metade da distância entre o ápice da cabeça e a margem anterior dos olhos. Fonte: Autor

2.2 Redes Neurais Artificiais

O neurônio artificial possui uma estrutura semelhante ao biológico, procurando imitar o comportamento do neurônio natural. Os modelos utilizados em redes neurais são não-lineares fornecendo saídas contínuas e realizando funções simples, como coletar os sinais existentes em suas entradas, agregá-los dependendo da função operacional e produzir uma resposta junto com sua função de ativação. Abaixo [10] apresenta o esquema de um neurônio com sua representação matemática de cada função, desde seus dados de entrada x até sua saída y .




Figura 2: Neurônio Artificial. Fonte: Silva, 2010

As expressões propostas por McCulloch e Pitts mostradas [10], sintetizam o resultado matemático assim:

$$u = \sum_{i=1}^n w_i x_i - \theta \tag{1}$$

$$y = g(u) \tag{2}$$

A arquitetura de uma rede neural artificial é a maneira pelas quais seus diversos neurônios estão intimamente arranjados, ou dispostos, uns aos outros. A arquitetura de uma rede está inteiramente ligada ao seu processo de aprendizagem ou processo de treinamento.

A propriedade mais importante em uma rede neural é a capacidade de aprender a partir do seu ambiente e de melhorar seu desempenho através do treinamento ao ser capaz de generalizar soluções ao produzir uma saída próxima daquela esperada. [11] afirma que a aprendizagem é um processo onde os parâmetros de uma rede são adaptados através de estimulação do ambiente que a rede está inserida.

Redes *Perceptron* Multicamadas são caracterizadas pela presença de camadas ocultas ou escondidas, bastantes usadas pelas elevadas possibilidades de sucesso para resolver diversos problemas difíceis como reconhecimento de padrões, aproximação universal de funções, previsão temporal, identificação e controle de processos e etc., usadas para resolver problemas que não são linearmente separáveis. São arquiteturas *feedforward* e utiliza-se treinamento supervisionado para adequar a rede as suas condições. A propagação do sinal nessa rede sempre é em um único sentido sendo da camada de entrada em direção a camada de saída.

Seu algoritmo de treinamento é o *backpropagation* também conhecido como Regra Delta generalizada [10] que consiste no cálculo do gradiente do erro para cada vetor de entrada; é um dos principais algoritmos de aprendizagem para redes neurais. Possui duas fases nos seus treinamentos chamadas de *forward* (propagação adiante) e *backward* (propagação reversa ou retropropagação). [12] afirma que a fase *forward* é usada para definir a saída para um dado padrão de entrada e a fase *backward* usa a saída desejada e a saída fornecida para atualizar os pesos e conexões. Em [13] é apresentado uma representação gráfica de como funciona as duas fases do algoritmo exibida abaixo.

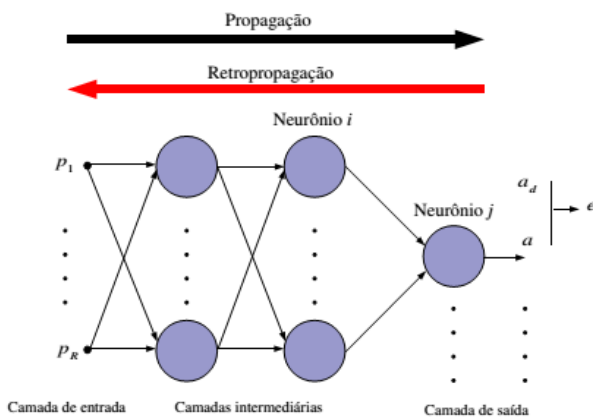


Figura 3: Funcionamento do Algoritmo *Backpropagation*. Fonte: Matsunaga, 2012

O objetivo do treinamento é fazer com que uma rede seja capaz de classificar padrões de exemplos de entrada diferentes dos utilizados no conjunto de treino. A essa capacidade se dá o nome de generalização. Porém, quando uma rede apenas classifica os padrões dos exemplos usados no conjunto de treinamento, tem-se a “memorização” ou *overfitting*. Uma boa generalização de uma rede está diretamente ligada ao tamanho do conjunto de treinamento e aos parâmetros de configuração fornecidos [11].

2.3 Processamento Digital de Imagens (PDI)

O objetivo do PDI consiste em melhorar o aspecto visual de certos objetos fornecendo informações para sua interpretação [14]. Deste modo, se extrai as informações necessárias para procedimentos de processo computacional. Uma imagem digital é uma função bidimensional contínua $f(x,y)$, na qual x e y são coordenadas espaciais e o valor de f em qualquer ponto (x,y) é proporcional à intensidade luminosa no ponto considerado [15]. Como os computadores não são capazes de processar imagens contínuas, mas apenas *arrays* de números digitais, é necessário representar imagens como arranjos bidimensionais de pontos. Cada ponto na grade bidimensional que representa a imagem digital é denominado elemento de imagem ou pixel.

Um dos pontos importantes para esta pesquisa no quesito de PDI é o pré-processamento através de histograma. Essa função representa uma imagem em nível de intensidade, fornecendo informações sobre a fotografia e denota a distribuição dos níveis de cinza. É representado por um gráfico que apresenta o número de *pixels* na imagem para cada nível de cinza sendo a sua distribuição estatística.




Figura 4: Imagem do Barbeiro e seu Histograma. Fonte: Autor

A etapa de analisar o histograma vem da finalidade de ajustar os tons de intensidade para realçar as diferenças de intensidade entre o inseto e fundo e também os tons encontrados no próprio inseto.

Foi também utilizado filtro passa alta de logaritmo nas imagens para atenuar ou eliminar *pixels* de baixa frequência e realçar os elementos de alta frequência.

3 DESENVOLVIMENTO

Este capítulo aborda o processo de criação da rede neural artificial e o processamento digital feito nas imagens de entrada. Além de apresentar como foi a abordagem da entrada da rede e o método usado para criar o vetor de entrada. Para esta pesquisa utilizamos apenas as imagens de três espécies, uma de cada gênero diferente que são encontrados na região do baixo Tocantins.

Vale ressaltar que esta rede classifica se a imagem de entrada pertence ao gênero *Panstrongylus* ou se pertence aos outros gêneros, ou seja *Rhodnius* ou *Eratyrus*, porque no momento da coleta das imagens não tinham tantos insetos exemplo dos outros gêneros apenas do *Panstrongylus*.

As espécies foram coletadas pelo 6º centro regional de saúde do estado do Pará através de coleta de campo que ocorrem anualmente no segundo semestre, contudo, em sua coleta para qual foi usada nesse trabalho, a quantidade de espécies encontradas não foi suficiente para retirar as fotografias, mas o necessário para comprovar que o reconhecimento de imagens funciona com uma acurácia aceitável.

As imagens do *dataset* foram manipuladas, retiradas com um fundo branco e capturadas próxima ao inseto a fim de visualizar particularidades encontradas em suas asas e sua cabeça para obter uma boa classificação.

Todo o processo da pesquisa foi realizado no software MATLAB [16] que possui pacotes de aplicação relacionados a redes neurais e também uma caixa de ferramentas para reconhecimento e classificação de padrões. Nesse pacote é possível criar, treinar, testar e validar a rede de uma forma prática.

3.1 Processamento das Imagens de Entrada

As imagens adquiridas possuem um tamanho em escala de milhões de *pixels*, o que dificultaria a classificação exigindo um alto poder de processamento e hardware para aplicação. Sendo assim, as imagens foram redimensionadas para um tamanho quadrático padrão.

No MATLAB as imagens são carregadas em uma matriz n linhas por m colunas de três dimensões (*Red*, *Green*, *Blue*) e armazenadas em uma variável. As etapas do processamento digital são as seguintes:

- **Etapa 1:** Essas matrizes foram transformadas em escala de cinza tornando-se assim, uma matriz bidimensional para facilitar a manipulação. Antes de aplicar as correções na figura, ela foi redimensionada para um tamanho menor de 400x400 *pixels* estabelecendo assim um tamanho padrão pré-definido;
- **Etapa 2:** Nesse ponto aplicou-se então a correção de contraste, ajustando a intensidade através da expansão de histograma equivalente ao *imadjust* no MATLAB. Os *pixels* da imagem são realçados destacando a diferença de intensidade entre os níveis de cinza;
- **Etapa 3:** Nesse passo a imagem foi convertida em precisão dupla ganhando valores entre 0 e 1 e então aplicado o filtro passa alta de *log* para atenuar ou eliminar

os componentes de baixa frequência além de realçar elementos de alta frequência. Após aplicação do filtro realçando as componentes, expande-se novamente o histograma da imagem para destacar a diferença de intensidade entre as duas frequências;

- **Etapa 4:** Os resultados obtidos por essa sequência de tratamentos foram aceitáveis para usá-los na rede pois as características importantes dos dados estavam visíveis na imagem, porém devido a aplicação do filtro passa alta a imagem escureceu, então fez-se a inversão de cores para uma melhor visualização.




Figura 5: (A) Imagem em escala de cinza com a primeira correção feita; (B) Processamento digital feito com expansão de histograma, filtro passa alta de LOG e expansão de histograma novamente; (C) Inversão de cores para melhor visualização das linhas e detalhes no tórax e no abdômen do triatomíneo. Fonte: Autor.

A aplicação *Pattern Recognition App* é um algoritmo que apresenta uma solução para um problema de classificação e reconhecimento de padrões. Sua arquitetura é do tipo *feed-forward* de duas camadas, sua camada escondida apresenta função de transferência sigmoide e a camada de saída é *softmax*, uma generalização da função logística que ajuda a convergir mais rapidamente na classificação de várias classes. É um padrão definido pela própria rede *patternnet*, que pode classificar os vetores arbitrariamente bem dependendo do número de neurônios na camada escondida. A rede é treinada com algoritmo *backpropagation* de gradiente conjugado escalado (*trainscg*) e função de desempenho entropia cruzada (*crossentropy*).




Figura 6: Arquitetura da Rede Neural usada, exibida pelo MATLAB. Fonte: Autor.

3.2 Vetor de Entrada

A imagem após tratada está em formato de matriz com tamanho 400x400 gerando então 160000 posições, contudo uma rede com tantas posições exigiria um poder computacional imenso para criar essa rede e treiná-la. Então para definir e organizar o vetor de entrada buscou-se um método eficiente onde os dados pudessem ser arranjados de forma simplificada sem comprometer a rede.

Para geração do vetor de entrada foi criado um vetor concatenado de 800 posições para cada imagem, onde as 400 primeiras posições são referentes a soma das colunas chamado de projeção vertical e as outras 400 correspondem a soma das linhas da matriz conhecido como projeção horizontal. Esse vetor representa as características extraídas da imagem correspondente e é utilizado como entrada no conjunto de treinamento, teste e validação da rede neural artificial aqui usada.

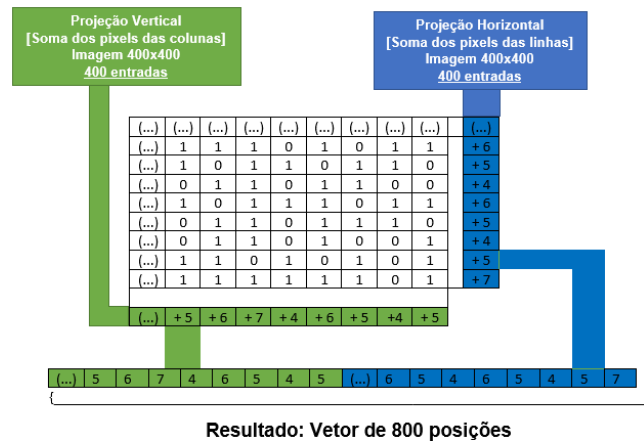


Figura 7: Extração das Características da Imagem. Fonte: Autor

O conjunto de dados consiste em 140 vetores de entrada correspondente a cada imagem organizados em uma matriz. Desse total, 94 imagens/dados são correspondentes ao gênero *panstrongylus* e 46 correspondentes aos outros dois gêneros, *rhodnius* e *eratyrys*. E existem dois tipos de saída possíveis da RNA: [1 0] significando que o vetor de entrada corresponde a uma imagem do gênero *panstrongylus* e [0 1] indicando que a entrada corresponde a uma figura de outro gênero.

Para a problemática foi criada uma rede neural artificial formada por 800 entradas correspondentes ao vetor de 800 posições, apenas uma camada escondida com 400 neurônios e dois neurônios na camada de saída com taxa de erro médio quadrático de 0,001.

4 RESULTADOS OBTIDOS

Foram analisados o comportamento da rede a partir do treinamento, suas taxas de erros e suas saídas apresentando o todo como resultado que compõe esse projeto.

Com a inserção dos dados na rede sendo 140 imagens no total foi então iniciado o treinamento que foi interrompido

após alcançar o erro quadrático de 10^3 após 52 épocas obtendo um desempenho aceitável.

A figura 8 plota a transição do valor de erro médio quadrático de acordo com o número de épocas. Geralmente o erro diminui de acordo com as épocas de treinamento, porém pode começar a aumentar no conjunto de dados de validação à medida que começa a sobre alcançar os dados de treinamento, ou seja, a rede tende a reconhecer somente os padrões que lhe foram ensinados. A essa particularidade se chama de *overfitting*.




Figura 8: Desempenho da Rede. Fonte: Autor.

A figura 9 apresenta a matriz de confusão de classificação apresenta o número e a porcentagem de classificações corretas nos quadrados verdes é bem alto e o baixo número de respostas incorretas nos quadrados vermelhos. Os quadrados azuis inferiores são as precisões gerais. Somente no teste obteve um resultado incorreto que não interferiu tanto ao final dando a rede um percentual de 99,3% de acertos e 0,7% de erros.

5 CONCLUSÃO

Neste trabalho foi realizado o processamento digital sobre as imagens dos triatomíneos que realçou as linhas e traços importantes que são necessários para o reconhecimento e a escolha de uma rede *Perceptron* Multicamadas com apenas uma camada escondida e o treinamento com o *Backpropagation* obteve um grau aceitável de acertos e de dissipação de erros entre os neurônios obtendo assim uma taxa de 99,03% de acurácia.

A rede criada neste projeto apresenta apenas o reconhecimento de um gênero de *triatomíneos* em uma saída e classificando os demais gêneros da região do baixo Tocantins na outra saída.

A intenção para um possível projeto futuro será expandir o classificador de padrões para os demais gêneros encontrados no Brasil cogitando também um possível classificador de espécies, além disso aumentar as características de entrada para receber também como vetor de entrada as imagens



Figura 9: Matriz de confusão e classificação. Fonte: Autor.

do indivíduo de lado e de bruços, aumentando sua taxa de acertos pelo motivo de aumentar seus números de espécies. Para realizar esse processo será buscado um novo ambiente de classificação como redes neurais profundas utilizando-se de *deep learning* para assim criar uma generalização, onde a rede possa classificar padrões que não lhe foram ensinados.

ACKNOWLEDGMENTS

Os autores gostariam de agradecer ao Programa de Pós-Graduação em Computação Aplicada (PPCA), ao Núcleo de Desenvolvimento Amazônico em Engenharia (NDAE) e à Universidade Federal do Pará (UFPA).

REFERENCES

- [1] Romain Raveaux Ingrid Arnault Damien Munier Maxime Martineau, Donatello Conte and Gilles Venturini. A survey on image-based insect classification. *Computers and Electronics in Agriculture – Elsevier*.
- [2] José A. Torres Alejandro López Francisco D. Molina-Aiz Karlos Espinoza, Diego L. Valera. Combination of image processing and artificial neural networks as a novel approach for the identification of *bemisia tabaci* and *frankliniella occidentalis* on sticky traps in greenhouse agriculture.
- [3] Rosli Ramli Arpah Abu, Lee Kien Leow and Hasmahzaiti Omar. Classification of *suncus murinus* species complex (soricidae: Crocidurinae) in peninsular malaysia using image analysis and machine learning approaches.
- [4] World Health Organization. Chagas disease (american trypanosomiasis). Disponível em: <https://www.who.int/chagas/en/>, 2017.
- [5] Centers for Disease Control and Prevention. Parasites - american trypanosomiasis (also known as chagas disease). Disponível em: <https://www.cdc.gov/parasites/chagas/>, 2017.
- [6] BR Almeida and FC Santiliano. Levantamento dos métodos de diagnóstico para a doença de chagas. *Enciclopédia biosfera, Centro Científico Conhecer-Goiânia*, 8(14):1586, 2012.

- [7] José Jurberg, Juliana MS Rodrigues, Felipe FF Moreira, Carolina Dale, Isabelle RS Cordeiro, and D Valdir Jr. Atlas iconográfico dos triatomíneos do brasil (vetores da doença de chagas), 2014.
- [8] José Rodrigues Coura and João Carlos Pinto Dias. Epidemiology, control and surveillance of chagas disease: 100 years after its discovery.
- [9] Ana Maria Argolo, Márcio Felix, Raquel Pacheco, and Jane Costa. Doença de chagas e seus principais vetores no brasil. In *Doença de Chagas e seus principais vetores no Brasil*. 2008.
- [10] Danilo Hernane Spatti Ivan Nunes da Silva and Rogério Andrade Flauzino. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. Fundamentos Teóricos e Aspectos Práticos*. Artliber, Sao Paulo, SP, 2nd. edition, 2016.
- [11] Simon Haykin. *Redes neurais: princípios e prática*. Bookman Editora, 2007.
- [12] A de P Braga. *Redes neurais artificiais: teoria e aplicações*. Livros Técnicos e Científicos, 2000.
- [13] Victoria Yukie Matsunaga. Curso de redes neurais utilizando o matlab. *Belém do Pará*, 2012.
- [14] Ogê Marques Filho and Hugo Vieira Neto. *Processamento digital de imagens*. Brasport, 1999.
- [15] José Eustáquio Rangel de Queiroz and Herman Martins Gomes. Introdução ao processamento digital de imagens. *RITA*, 13(2): 11–42, 2006.
- [16] Mathworks. Documentation. Disponível em: <https://www.mathworks.com/help/>, 2017.