

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Escola de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Bruno Alberto Soares Oliveira

**DIAGNÓSTICO AUTOMÁTICO DE OVOS DE PARASITOS
INTESTINAIS HUMANOS A PARTIR DE IMAGENS
MICROSCÓPICAS UTILIZANDO REDES NEURAIS
CONVOLUCIONAIS**

Belo Horizonte

2020

Bruno Alberto Soares Oliveira

**Diagnóstico Automático de Ovos de Parasitos Intestinais
Humanos a partir de Imagens Microscópicas utilizando Redes
Neurais Convolucionais**

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Frederico Gadelha Guimarães

Belo Horizonte

2020

O48d

Oliveira, Bruno Alberto Soares.

Diagnóstico automático de ovos de parasitos intestinais humanos a partir de imagens microscópicas utilizando redes neurais convolucionais [recurso eletrônico] / Bruno Alberto Soares Oliveira. - 2020.

1 recurso online (56 f. : il., color.) : pdf.

Orientador: Frederico Gadelha Guimarães.

Dissertação (mestrado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Bibliografia: f. 52-56.

Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia elétrica - Teses. 2. Diagnóstico por imagem - Teses. 3. Doenças parasitárias - Teses. 4. Intestinos - Parasitos - Teses. 5. Redes neurais convolucionais - Teses. I. Guimarães, Frederico Gadelha. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.

CDU: 621.3(043)

Ficha catalográfica elaborada pela Bibliotecária Roseli Alves de Oliveira - CRB-6/2121
Ficha catalográfica: Biblioteca Profº Mário Werneck, Escola de Engenharia da UFMG

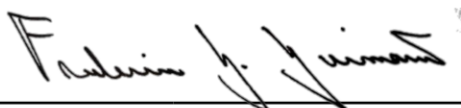
**"Diagnóstico Automático de Ovos de Parasitos Intestinais
Humanos A Partir de Imagens Microscópicas Utilizando Redes
Neurais Convolucionais"**

Bruno Alberto Soares Oliveira

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 18 de setembro de 2020.

Por:



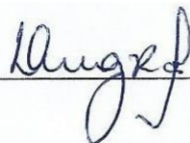
Prof. Dr. Frederico Gadelha Guimarães
DEE (UFMG) - Orientador



Prof. Dr. Eduardo Mazoni Andrade Marçal Mendes
DELT (UFMG)



Prof. Dr. Ricardo de Oliveira Duarte
(UFMG)



Prof. Dr. Deborah Aparecida Negrão-Corrêa
Parasitologia (UFMG)

Dedico este trabalho em primeiro lugar a Deus, que sempre me iluminou durante essa longa e dura jornada.

*A minha mãe, que sempre orou por mim, torcendo pelo meu sucesso.
Ao meu pai, que sempre me incentivou e é um exemplo a ser seguido.*

Agradecimentos

Primeiramente, agradeço a Deus, que jamais saiu do meu lado. À minha mãe, que me ajudou a caminhar na fé e acreditar nos impossíveis da vida. Ao meu pai, exemplo de integridade, que me ensinou que a vida é um eterno sonhar e recomeçar. À minha namorada, que esteve comigo nas dificuldades do curso. À minha madrinha, tias e tios, primos e primas, e a todos os meus familiares que sempre acreditaram em mim.

Agradeço, também, aos meus velhos amigos de infância, que até hoje caminham comigo. Também aos meus colegas que tiveram alegrias e tristezas, ao longo desses dois anos de curso. Aos meus professores, que sempre exigiram o máximo de mim e, ainda, a todos os funcionários da Universidade, que diretamente ou não, contribuíram para esse sucesso por mim alcançando.

A todos do laboratório MINDS, por viverem comigo essa experiência fantástica, enriquecendo toda pesquisa desenvolvida por mim durante essa temporada. Um agradecimento especial ao meu orientador, Prof. Frederico Gadelha Guimarães, por ter sido literalmente um orientador por todo esse tempo, parabenizando e criticando construtivamente todas as vezes em que se foi necessário. A equipe do Laboratório de Imunologia de Helminhos do Instituto de Ciências Biológicas, pela coleta e disponibilização dos dados que possibilitaram a pesquisa.

Por fim, agradeço a toda equipe do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais pela oportunidade de desenvolver o trabalho e a CAPES pelo apoio financeiro.

Obrigado! Vocês foram fundamentais nessa vitória!

“Todo mundo é um gênio. Mas, se você julgar um peixe por sua capacidade de subir em uma árvore, ele vai gastar toda a sua vida acreditando que é um estúpido”.

(Albert Einstein)

Resumo

Uma das maiores preocupações da área de saúde pública são causadas pelos parasitos intestinais humanos, que são encontrados em grande parte nos países tropicais. O diagnóstico dessas doenças parasitárias se dá por meio de sintomas fisiológicos e exame fecal. Frequentemente, poucos profissionais estão disponíveis e aptos a realizarem esse tipo de exame, que é considerado lento, difícil, propenso a erros e pode causar fadiga ocular no especialista. A área de reconhecimento de padrões em imagens apresenta-se como uma alternativa promissora como apoio e automatização de exames baseados em imagens. Além disso, técnicas de aprendizado profundo têm sido aplicadas com sucesso para esse propósito. Portanto, o objetivo desse trabalho é utilizar redes neurais convolucionais para classificar ovos de parasitos intestinais, sendo um sistema de auxílio a tomada de decisão no diagnóstico de um exame de fezes. Foi construída uma base de dados real com 66 imagens de diferentes espécies de ovos de parasitos (*Ancylostoma duodenale*, *Necator americanus*, *Ascaris lumbricoides*, *Enterobius vermicularis*, *Schistosoma mansoni* e *Trichuris trichiura*). Técnicas de *data augmentation* foram utilizadas para se obter um maior número de amostras, tendo no final um total de 48 mil imagens. Foram realizados experimentos empíricos de modo a definir uma arquitetura da rede específica para cada problema. A maior dificuldade do diagnóstico do especialista é na localização dos ovos misturados a impurezas e sujeiras contidas na lâmina, por isso, foi implementada uma arquitetura de Rede Neural Convolucional visando resolver um problema de classificação binária e outra para um problema de classificação multiclasse. Os resultados obtidos demonstraram uma taxa de reconhecimento de 99.9%, para todas as métricas avaliadas. A aplicação desenvolvida será uma parte essencial de um futuro sistema que será totalmente automatizado.

Palavras-chave: Diagnóstico por Imagens Médicas, Doenças Parasitárias, Imagem Microscópica Óptica, Ovos de Parasitos Intestinais, Redes Neurais Convolucionais.

Abstract

One of the biggest concerns in the area of public health is caused by human intestinal parasites, which are found largely in tropical countries. The diagnosis of these parasitic diseases is done through physiological symptoms and fecal examination. Often, few professionals are available and able to perform this type of examination, which is considered slow, difficult, prone to errors, and can cause eye strain in the specialist. The area of pattern recognition in images presents itself as a promising alternative as support and automation of exams based on images. Also, deep learning techniques have been successfully applied for this purpose. Therefore, the objective of this work is to use convolutional neural networks to classify eggs from intestinal parasites, being a system to aid decision making in the diagnosis of a stool test. A real database was built with 66 images of different species of parasite eggs (*Ancylostoma duodenale*, *Necator americanus*, *Ascaris lumbricoids*, *Enterobius vermicularis*, *Schistosoma mansoni*, and *Trichuris trichiura*). *Data augmentation* techniques were used to obtain a larger number of samples, with a total of 48 thousand images at the end. Empirical experiments were carried out to define a specific network architecture for each problem. The greatest difficulty of the specialist's diagnosis is in locating the eggs mixed with impurities and dirt contained in the slide, for this reason, a Convolutional Neural Network architecture was implemented to solve a binary classification problem and another for a multiclass classification problem. The results obtained demonstrated a recognition rate of 99.9%, for all metrics evaluated. The developed application will be an essential part of a future system that will be fully automated.

Keywords: Diagnosis by Medical Images, Parasitic Diseases, Optical Microscopic Image, Intestinal Parasites Eggs, Convolutional Neural Networks.

Lista de Ilustrações

| | |
|--|----|
| Figura 1 – Exemplo de ovo da espécie <i>Schistosoma mansoni</i> em um campo microscópico. | 16 |
| Figura 2 – Exemplo da utilização da técnica Kato-Katz em um campo microscópico. | 17 |
| Figura 3 – Esquema de um neurônio simples. | 22 |
| Figura 4 – Perceptron de múltiplas camadas. | 23 |
| Figura 5 – Esquema de uma rede neural convolucional. | 25 |
| Figura 6 – Exemplo da matriz de confusão. | 28 |
| Figura 7 – Fluxograma do sistema proposto. | 33 |
| Figura 8 – Exemplos de imagens contidas no conjunto de dados utilizado. | 36 |
| Figura 9 – Arquitetura da CNN para o problema de classificação binário. | 42 |
| Figura 10 – Arquitetura da CNN para o problema de classificação multiclasse. | 43 |
| Figura 11 – Mapa de calor que representa a classificação de cada uma das 4000 imagens de sujeira submetidas a arquitetura multiclasse. | 46 |

Lista de Tabelas

| | |
|--|----|
| Tabela 1 – Resultados dos experimentos realizados com os ovos do grupo dos Ancilostomídeos. | 43 |
| Tabela 2 – Resultados dos experimentos realizados com os ovos da espécie <i>Ascaris lumbricoides</i> | 44 |
| Tabela 3 – Resultados dos experimentos realizados com os ovos da espécie <i>Enterobius vermicularis</i> | 44 |
| Tabela 4 – Resultados dos experimentos realizados com os ovos da espécie <i>Schistosoma mansoni</i> | 44 |
| Tabela 5 – Resultados dos experimentos realizados com os ovos da espécie <i>Trichuris trichiura</i> | 44 |
| Tabela 6 – Resultados dos experimentos realizados com os ovos de todas as espécies estudadas nessa pesquisa. | 45 |
| Tabela 7 – Resultados dos experimentos utilizando transfer learning. | 49 |

Lista de Abreviaturas e Siglas

| | |
|-------|---|
| CNN | Rede Neural Convolutacional |
| FN | Falso Negativo |
| FP | Falso Positivo |
| IA | Inteligência Artificial |
| MINDS | Machine Intelligence and Data Science |
| MLP | Perceptron Multicamadas |
| MCSVM | Máquina de Vetores de Suporte Multiclasse |
| RNA | Rede Neural Artificial |
| SUS | Sistema Único de Saúde |
| SVM | Máquina de Vetores de Suporte |
| UFMG | Universidade Federal de Minas Gerais |
| VN | Verdadeiro Negativo |
| VP | Verdadeiro Positivo |

Sumário

| | | |
|----------|---|-----------|
| 1 | Introdução | 11 |
| 1.1 | Motivação | 11 |
| 1.2 | Objetivo Geral | 13 |
| 1.3 | Organização do Trabalho | 14 |
| 2 | Referencial Teórico | 15 |
| 2.1 | Problema de Interesse | 15 |
| 2.2 | Método Kato-Katz | 16 |
| 2.3 | Aprendizado de Máquina | 18 |
| 2.3.1 | Problema de Classificação | 19 |
| 2.3.2 | Aprendizado Supervisionado | 19 |
| 2.4 | Deep Learning | 20 |
| 2.4.1 | Transfer Learning | 21 |
| 2.5 | Redes Neurais Artificiais | 22 |
| 2.6 | Redes Neurais Convolucionais | 24 |
| 2.7 | Data Augmentation | 26 |
| 2.8 | Métricas de Avaliação dos Resultados | 26 |
| 2.8.1 | Matriz de Confusão | 27 |
| 2.8.2 | Métricas de Qualidade | 28 |
| 2.8.2.1 | Acurária | 28 |
| 2.8.2.2 | Precisão (especificidade) | 29 |
| 2.8.2.3 | Revocação (sensibilidade) | 29 |
| 2.8.2.4 | F1-score | 29 |
| 2.9 | Estado da Arte | 30 |
| 2.10 | Resumo | 32 |
| 3 | Material e Métodos | 33 |
| 3.1 | Criação do Dataset | 33 |
| 3.2 | Definição da Arquitetura e Implementação da CNN | 36 |
| 3.3 | Avaliação de Desempenho de Classificação | 38 |
| 3.4 | Comparativo Entre Modelos | 39 |

| | | |
|----------|--|-----------|
| 3.5 | Resumo | 39 |
| 4 | Resultados e Discussão | 41 |
| 4.1 | Arquitetura da CNN | 41 |
| 4.2 | Experimentos Utilizando Arquiteturas Propostas | 43 |
| 4.3 | Experimentos Utilizando Transfer Learning | 48 |
| 4.4 | Resumo | 49 |
| 5 | Conclusões | 50 |
| 5.1 | Trabalhos Futuros | 51 |
| | Referências | 52 |

Capítulo 1

Introdução

1.1 Motivação

Parasitas são organismos que necessitam de outros organismos para sobreviver, sendo estes, hospedeiros. Para se manterem vivos, os parasitos utilizam recursos fisiológicos do hospedeiro para se nutrirem e serem capazes de reproduzirem. Atualmente, estima-se que existam 4 bilhões de pessoas infectadas por doenças parasitárias em todo o mundo, sendo que em crianças e pessoas imunodeficientes as infecções podem causar maiores distúrbios físicos ou comportamentais e, nos piores casos, levar o indivíduo a morte ([WHO, 2018](#)).

Dentre essas 4 bilhões, estima-se que 700 milhões de pessoas estão infectadas pela espécie *Ascaris lumbricoides* ([Mohammadzadeh et al., 2019](#)) e que a esquistossomose afeta cerca de 220 milhões de pessoas que vivem em áreas tropicais e subtropicais de 78 países na África, América e Ásia ([WHO, 2020](#)). Grande parte dessas pessoas infectadas são assintomáticas, o que apresenta um problema, uma vez que o indivíduo contaminado pode vir a transmitir a doença para pessoas saudáveis.

Existem três principais classes de parasitos que podem causar doenças em humanos: protozoários, helmintos e ectoparasitos. Em estudos anteriores, foi verificado que alguns helmintos têm maior prevalência e podem ser encontrados em amostras de fezes positivas, são eles: *Ancylostoma duodenale*, *Necator americanus*, *Ascaris lumbricoides*, *Enterobius vermicularis*, *Schistosoma mansoni* e *Trichuris trichiura*, não necessariamente nessa ordem de prevalência. Esses mesmos estudos relataram que a maior prevalência destes parasitos

se deve à forma de infecção de cada um deles (Gomes et al., 2002; Kucik et al., 2004).

O diagnóstico de um paciente com suspeita de infecção parasitológica pode variar de acordo com a disponibilidade do médico e dos recursos que o mesmo possui. O médico se utiliza dos sinais clínicos do paciente e o histórico individual para avaliar a necessidade de fazer o pedido de um teste diagnóstico para helmintíases. Em grande parte dos casos, esse diagnóstico pode ser difícil, por isso é muito comum que o profissional solicite mais de um tipo de exame.

O exame clínico é o primeiro passo para o diagnóstico, sendo o exame parasitológico de fezes o teste mais comum utilizado para esse tipo de diagnóstico. Uma das técnicas mais aplicadas nesse tipo de exame é o esfregaço de fezes espesso de Kato-Katz (Katz et al., 1972). Esse método possui as vantagens de ser barato e fácil de se obter resultados qualitativos e quantitativos sobre a presença e a carga parasitária das infecções intestinais mais comuns por helmintos, também da esquistossomose intestinal. Além disso, a técnica Kato-Katz é um bom exame para detectar pessoas com poucos ovos nas fezes, pois utiliza mais material fecal na lâmina, em comparação a outros métodos.

Especialistas treinados, a partir de seu conhecimento prévio e com o auxílio de um microscópio, examinam o material fecal do paciente em busca de ovos de parasitos. Salienta-se que todo esse processo é realizado de forma manual pelo especialista, em que é comum acontecer erros de diagnóstico devido ao cansaço, fadiga e falta de experiência do profissional (De Carli, 2001; Neves, 2003), resultando em taxas de falsos negativos, especialmente em casos em que se há um baixo número de ovos no material (Tarafder et al., 2010).

Além disso, em áreas endêmicas, os sistemas de saúde governamentais fazem ações de diagnóstico em uma amostra da população. Nesses casos, grande parte dos indivíduos possuem uma baixa carga de ovos de parasitos, o que dificulta ainda mais o trabalho dos agentes de saúde. Em situações dessa natureza, é comumente utilizado o exame de fezes, uma vez que o mesmo é barato em relação a outros exames e, portanto, bastante útil em larga escala.

Para resolver o problema da falta de especialistas treinados para uma tomada de decisão correta (Oliveira et al., 2018; Assis et al., 2019) e diminuir o tempo necessário para o diagnóstico a partir do exame parasitológico manual de fezes, é necessário o

desenvolvimento de tecnologias que possam ser capazes de automatizar esse processo. A classificação automática de ovos de parasitos em exames fecais permitirá a inspeção de um maior número de amostras com um alto grau de confiabilidade e objetividade. A tecnologia será útil, principalmente, nos países onde se tem um alto índice de pessoas infectadas por meio de doenças parasitológicas.

Nos últimos anos os estudos em aprendizado profundo (*deep learning*) vêm se difundindo e suas aplicações vêm se tornando cada vez mais presentes no dia a dia da sociedade. *Deep learning* pode ser entendido como uma família de métodos de aprendizado de máquina que são baseados em redes neurais artificiais (RNA). Esse tipo de aprendizado pode ser supervisionado, semi-supervisionado ou não supervisionado.

Atualmente, um dos principais algoritmos de aprendizado de máquina são as redes neurais convolucionais, também conhecidas como CNNs ou ConvNets. Elas pertencem a uma classe de redes neurais profundas e são constantemente aplicadas em problemas de classificação e detecção de objetos em imagens.

Uma rede neural convolucional é um algoritmo de aprendizado profundo que recebe uma imagem como entrada. Logo depois, essa imagem é processada e o algoritmo extrai as características mais relevantes de algum objeto pré-determinado contido na imagem para que, em seguida, consiga diferenciar um ou mais objetos baseado nos padrões aprendidos. Feito isso, o algoritmo consegue rotular cada um dos objetos e dizer a qual classe pertencem.

Distinto dos demais trabalhos na literatura que utilizam transformadas e operações morfológicas com filtros já pré-estabelecidos para extraírem as características de cada espécie de ovo de parasito, no modelo desenvolvido foi utilizado redes neurais convolucionais, técnica que ajusta adequadamente na etapa de treinamento, os valores dos pesos dos filtros que realçam as características mais importantes de cada espécie de ovo para posterior classificação.

1.2 Objetivo Geral

O objetivo principal deste trabalho é propor um modelo que utiliza Redes Neurais Convolucionais e seja capaz de classificar ovos de diferentes espécies de parasitos humanos, que são: *Ancylostoma duodenale*, *Necator americanus*, *Ascaris lumbricoides*, *Enterobius*

vermicularis, *Schistosoma mansoni* e *Trichuris trichiura*, de modo que o mesmo seja utilizado por profissionais da saúde, os auxiliando na tomada de decisão em diagnósticos de doenças parasitárias.

1.3 Organização do Trabalho

Essa dissertação é organizada da seguinte forma:

No capítulo 2 é apresentado o referencial teórico, em que são definidos importantes conceitos para o bom entendimento do trabalho, como o problema de interesse, o que é o método Kato-Katz, aprendizado de máquina, *deep learning*, redes neurais artificiais, redes neurais convolucionais, as técnicas de *data augmentation* e sobre as métricas de avaliação dos resultados utilizadas nessa pesquisa. Também é nesse capítulo que foram discutidos os resultados dos estudos de outros autores utilizando técnicas de inteligência artificial na detecção de ovos de parasitos.

O capítulo 3 apresenta os materiais e os métodos utilizados no desenvolvimento desse trabalho, como a criação da base de imagens utilizada, como foi definida a arquitetura da CNN proposta e como o modelo foi avaliado. Aqui são descritas todas as etapas de aquisição do material e realização dos experimentos, de forma que o trabalho possa ser executado por outros pesquisadores, para a replicabilidade.

O capítulo 4 apresenta os resultados obtidos após uma grande quantidade de experimentos realizados, os quais foram descritos no capítulo 3. Nesse capítulo tem-se a discussão dos resultados encontrados para as arquiteturas propostas após a realização dos experimentos empíricos. Além disso, a análise da aplicação do aprendizado por transferência no problema multiclasse abordado.

Já o capítulo 5 fornece as considerações conclusivas, algumas limitações e indica oportunidades de novas pesquisas, uma vez que o algoritmo apresentado nesse trabalho será parte essencial de um futuro sistema que permitirá automatizar a detecção de ovos de parasitos para o diagnóstico em exames fecais.

Capítulo 2

Referencial Teórico

O capítulo de Referencial Teórico consiste num resumo de discussões já feitas por outros autores sobre os estudos realizados nas áreas de parasitologia e inteligência artificial, servindo como embasamento para o desenvolvimento do tema aqui abordado. Foi consultada as referências bibliográficas condizentes com a atual linha de interesse e foi verificada as pesquisas previamente desenvolvidas por alguns autores sobre a mesma temática.

No referencial teórico são apresentados os mais importantes conceitos, justificativas e características sobre o assunto abordado, do ponto de vista da análise feita por outros autores. Também foi descrito sobre os resultados das pesquisas que foram obtidas previamente, indicando os respectivos responsáveis pelas análises, criando um plano de sustentação argumentativo, dando embasamento e servindo como comparação em relação aos resultados a serem obtidos a partir do trabalho desenvolvido.

2.1 Problema de Interesse

Atualmente, as técnicas realizadas no setor de parasitologia são exclusivamente manuais, podendo ser influenciadas possivelmente por variáveis não controláveis como a atenção e a experiência do técnico laboratorial. A identificação dos ovos de parasitos é determinada microscopicamente, por um profissional habilitado, de acordo com a morfologia dos ovos. A Figura 1 ilustra um campo microscópico (ampliação de 100x) de um esfregaço fecal de Kato-Katz, contendo um ovo de *Schistosoma mansoni* (círculo vermelho), que foi previamente detectado por um aluno treinado de pós-graduação.




Figura 1 – Exemplo de ovo da espécie *Schistosoma mansoni* em um campo microscópico.

Como pode ser observado na Figura 1, a tarefa de detecção de ovos de parasitos em uma amostra fecal não é intuitiva para ser feita manualmente. A maior dificuldade que os especialistas enfrentam é o alto acúmulo de sujeira, fungos, bolhas de água etc. na placa, o que dificulta a localização dos ovos. Um outro problema é a quantidade elevada de falsos negativos que existem nos diagnósticos com esse tipo de análise, que é quando o especialista deixa de notar algum ovo na amostra fecal e dá ao paciente um diagnóstico equivocado, o que não é incomum em casos de baixa carga parasitária.

2.2 Método Kato-Katz

O método Kato-Katz é uma técnica quantitativa empregada quando se deseja conhecer a carga parasitária em uma lâmina, ou seja, estimar a quantidade de ovos de helmintos que um determinado indivíduo está eliminando em suas fezes. É possível utilizar essa técnica a partir de fezes frescas ou conservadas em formaldeído. Em fezes preservadas, as mesmas não podem estar no estado líquido e o conservante empregado deve ser descartado no momento do exame (Katz et al., 1972).

Devido sua simplicidade e objetividade, o método Kato-Katz é a principal técnica

de diagnóstico de presença de helmintos e atualmente é considerada sendo a única técnica utilizada em exames de rotina nos serviços públicos e privados de saúde e em laboratórios de pesquisa, devido à sua rápida preparação e à facilidade em se obter as amostras para varredura.

A Figura 2 ilustra um campo microscópico (ampliação de 100x) de um esfregaço fecal de Kato-Katz, contendo ovos de Ancilostomídeo (A), *Ascaris lumbricoides* (B), *Enterobius vermicularis* (C) e *Trichuris trichiura* (D), cada um marcado pela cor vermelha, que foi previamente detectado por um aluno treinado de pós-graduação.




Figura 2 – Exemplo da utilização da técnica Kato-Katz em um campo microscópico.

Os materiais necessários para uso dessa técnica são: o kit Kato-Katz, um microscópio binocular, algumas máscaras, avental, luvas e lâminas. Para preparação das lâminas é necessário que a amostra seja realizada a partir de fezes frescas (ou mantidas na geladeira por até 48 horas) e não diarréicas. Com os materiais disponíveis, o técnico laboratorial irá seguir uma determinada metodologia padrão conforme descrita por [Barbosa et al. \(2017\)](#).

Posteriormente a realização desse procedimento e com o auxílio de um microscópio óptico, o técnico irá conseguir de forma mais clara, visualizar os ovos de helmintos contidos na amostra fecal.

Existem algumas limitações do método, sendo que em grande parte das dificuldades dos técnicos laboratoriais se baseiam na ausência de ovos nas fezes. Mesmo para aqueles indivíduos que possuem alguma doença parasitária pode acontecer de, devido a certas circunstâncias, tais indivíduos não possuírem uma alta carga parasitária, levando geralmente a casos de diagnósticos que possuem como resultado o falso negativo (Barbosa et al., 2017).

2.3 Aprendizado de Máquina

Para Michie et al. (1994), aprendizado de máquina é uma aplicação de inteligência artificial (IA) que fornece aos sistemas computacionais uma certa capacidade de aprender e melhorar de forma autônoma a partir da sua própria experiência, fazendo com que não se torne necessário que tal sistema seja explicitamente programado. O aprendizado de máquina se concentra no desenvolvimento de programas de computador que podem acessar dados e usá-los para aprender por si próprios.

O processo de aprendizado começa com observações ou dados, como exemplos, a fim de procurar padrões nos dados e tomar melhores decisões no futuro com base nos exemplos que foram fornecidos. O principal objetivo é permitir que os computadores aprendam automaticamente sem que haja intervenção ou assistência humana e ajustem seus parâmetros implicitamente buscando resolver problemas de classificação ou de regressão.

Os algoritmos de aprendizado de máquina permitem a análise de grandes quantidades de dados. Embora geralmente ofereça resultados mais rápidos e precisos para identificar oportunidades lucrativas ou riscos perigosos, também pode exigir tempo e recursos adicionais para realizar a etapa de treinamento do modelo adequadamente. A combinação de aprendizado de máquina com IA e tecnologias cognitivas pode tornar essa classe de algoritmos ainda mais eficiente no processamento de grande volume de informações (Castoril et al., 2018; Nunes et al., 2020).

2.3.1 Problema de Classificação

No campo do aprendizado de máquina, um problema de classificação consiste em identificar corretamente a classe à qual uma determinada amostra pertence, com base em um conjunto de dados de treinamento que contém observações de mesma categoria conhecida. Alguns exemplos amplamente utilizados que buscam explicar esse tipo de problema são os casos de classificação de e-mails, em que os mesmos podem ser classificados como spam ou como não spam (Alpaydin, 2014).

Um algoritmo que implementa a classificação, especialmente em uma implementação concreta, é conhecido como classificador. O termo classificador às vezes também se refere a uma função matemática, implementada por um algoritmo de classificação que mapeia os dados de entrada para uma determinada categoria.

2.3.2 Aprendizado Supervisionado

Os algoritmos de aprendizado de máquina são geralmente classificados como supervisionados ou não supervisionados. O aprendizado supervisionado é um tipo de sistema no qual são fornecidos os dados de entrada e de saída desejados. Os dados de entrada e saída são rotulados para fornecer uma base de aprendizado com o intuito de classificar futuramente dados não rotulados (Rosenberg et al., 2005).

O aprendizado supervisionado ocorre quando um sistema recebe variáveis de entrada e saída com a intenção de aprender como tais variáveis são mapeadas. O objetivo é descobrir uma função de mapeamento para que, quando novas entradas desconhecidas forem fornecidas, o modelo possa prever a saída. Esse é um processo iterativo e, toda vez que o algoritmo faz uma previsão, ele é corrigido ou recebe um feedback até atingir um nível aceitável de desempenho (Rosenberg et al., 2005).

Um dos métodos de atualização dos parâmetros internos bastante utilizado no treinamento de redes multicamada é o *backpropagation*, proposto por Hecht-Nielsen (1992). De forma resumida, o método funciona inicialmente calculando o erro da camada de saída da arquitetura do modelo, comparando com o valor esperado. Os pesos entre a camada de saída e a camada anterior são atualizados para diminuir o erro e assim o gradiente do erro é repassado à camada anterior. Esse processo é realizado até que todos os pesos até a camada de entrada sejam atualizados.

Os dados de treinamento para essa classe de algoritmos incluem um conjunto de exemplos com assuntos de entrada relacionados e uma saída desejada. Por exemplo, em uma aplicação de aprendizado supervisionado com imagens, um sistema de IA pode receber imagens rotuladas de veículos em categorias como carros ou caminhões. Após o processo de observação dessas imagens e a etapa de treinamento concluída, o sistema deve ser capaz de distinguir e categorizar imagens não identificadas, como pertencente a uma das duas classes.

As aplicações do aprendizado supervisionado são tipicamente divididas em duas categorias, classificação e regressão. A classificação é semelhante ao exemplo acima, quando o valor de saída é uma categoria, como um carro ou um caminhão. Um problema de regressão ocorre quando a saída é um valor real calculado, como preço, peso, temperatura ou umidade.

2.4 Deep Learning

Deep learning, em português, aprendizado profundo, é uma técnica de aprendizado de máquina que visa “ensinar” as máquinas a agirem e interpretarem dados de uma maneira mais natural (Deng et al., 2014). O *deep learning* tem diversas aplicações, como por exemplo em veículos autônomos, em que o automóvel consegue reconhecer e identificar o estado atual de um semáforo, para que tome a decisão de parar antes do cruzamento ou prosseguir pela via.

Atualmente, o *deep learning* vem sendo aplicado em diversos ramos da pesquisa e da indústria, pelo fato de que essa técnica tem alcançado resultados que antes não eram possíveis. Até então, métodos tradicionais realizavam o trabalho de extração de características de forma manual, ficando a cargo do desenvolvedor definir as melhores estratégias. Com o advento do aprendizado profundo, essa seleção dos melhores recursos é realizada de forma automática, implicando diretamente nos resultados obtidos.

Utilizando a técnica de *deep learning*, um modelo é capaz de aprender a executar corretamente a tarefa de classificação de imagens, texto ou som. Tais modelos podem alcançar resultados extremamente precisos e, em muitos casos, possuem desempenho superior ao de um humano. Os modelos são treinados usando um grande conjunto de dados rotulados e arquiteturas de redes neurais artificiais que possuem muitas camadas ocultas.

De acordo com [Schmidhuber \(2015\)](#), para se conseguir resultados precisos e satisfatórios ao se utilizar *deep learning*, basicamente é necessário entender duas premissas. A primeira é que *deep learning* requer uma grande quantidade de dados rotulados, ou seja, é necessário milhares de imagens de cada espécie de animal, para se ter um modelo que classifica corretamente tais espécies por meio de imagens. A segunda é que *deep learning* requer um alto poder computacional, tal que seja necessário a utilização de GPUs, configuração de arquitetura paralela, entre outros.

Grande parte dos métodos de *deep learning* utilizam arquiteturas de redes neurais artificiais e, por isso, tais modelos são frequentemente chamados de redes neurais profundas. Geralmente as redes neurais tradicionais possuem apenas duas ou três camadas ocultas, enquanto as redes neurais profundas podem ter centenas. Tal profundidade permite que o modelo aprenda características diretamente dos dados rotulados, sem a necessidade de uma extração manual de características.

2.4.1 Transfer Learning

Atualmente existem três maneiras de se criar e treinar modelos de *deep learning* que têm como objetivo realizar a classificação de objetos, são eles: treinamento a partir do zero, extração de recursos e o *transfer learning*, em português, aprendizado por transferência. No treinamento a partir do zero é definida uma nova arquitetura da rede e seus parâmetros são inicializados aleatoriamente e, dependendo da quantidade de dados e a taxa de aprendizado, esse tipo de treinamento pode levar dias ou até semanas para que se conclua o aprendizado. A abordagem da extração de recursos usa a rede como tal extrator, em que se aprende recursos a partir de imagens e posteriormente utilizá-los como um modelo de aprendizado de máquina, como uma *Support Vector Machine* (SVM), por exemplo ([Erhan et al., 2010](#)).

Para [Pan and Yang \(2009\)](#), grande parte dos modelos de aprendizado profundo desenvolvidos atualmente utilizam essa abordagem de aprendizado por transferência, o qual é caracterizado por ser um processo que envolve o ajuste fino dos parâmetros em um modelo que já foi previamente treinado, utilizando outros dados e outros recursos.

O processo de *transfer learning* se dá início com uma rede já existente, como a AlexNet ([Krizhevsky et al., 2012](#)) ou GoogleNet ([Szegedy et al., 2015](#)). Posteriormente, com os dados rotulados, treina-se um classificador com os exemplos do novo problema. É

possível, na etapa de treinamento, ajustar alguns parâmetros da rede pré-treinada como por exemplo, ajustar os pesos sinápticos de apenas algumas camadas da arquitetura, congelando as demais. A maior vantagem desse tipo de abordagem se dá pelo fato de que é necessário um número bem menor de dados, de forma que o tempo de computação na etapa de treinamento reduza consideravelmente.

O processo de aprendizado por transferência requer uma configuração adequada de interface com os parâmetros da rede pré-treinada, para que tais valores possam ser ajustados e aprimorados para a nova tarefa. Atualmente existem inúmeras bibliotecas que auxiliam o desenvolvedor que opta por utilizar esse tipo de abordagem em seus modelos.

2.5 Redes Neurais Artificiais

As primeiras implementações das RNAs tiveram como inspiração os sistemas neurais biológicos, porém, atualmente, esses dois sistemas possuem poucas semelhanças. No começo dos estudos sobre o tema, foi desenvolvido uma estrutura computacional que continha semelhanças a um simples neurônio natural, que recebia dados de entrada, multiplicava esses dados por valores reais chamados pesos sinápticos, combinava o resultado dessas multiplicações produzindo um valor de ativação, que era passado como parâmetro à outra função para se gerar um dado de saída, como pode ser visto na Figura 3. Com o avanço dos estudos, os então chamados neurônios artificiais começaram a ser combinados em diferentes topologias de redes, criando-se, então, as RNAs (Barreto, 2002).




Figura 3 – Esquema de um neurônio simples.

Uma definição para uma RNA seria um sistema dinâmico complexo, pois através das ligações entre neurônios ela se torna uma rede de sistemas interconectados, que pode ser

representada por um grafo ponderado e direcionado, onde os vértices são as conexões entre os neurônios, os pesos dos vértices são os pesos sinápticos e os nós do grafo representam os componentes do neurônio que fazem as combinações dos valores e geram as saídas (Barreto, 2002).

Um modelo Perceptron simples é composto por um único neurônio e consegue realizar apenas separações lineares cujos objetos podem ser classificados em apenas dois grupos. Com a combinação de vários Perceptrons, em uma topologia com camadas de neurônios, foi possível classificar objetos não-linearmente separáveis em muitos grupos, como também realizar aproximações de funções complexas e previsões de dados (Flores, 2009).

A Figura 4 ilustra uma MLP com x_n entradas de dados em sua camada de entrada, que são multiplicados pelos pesos sinápticos e combinados em n_1 neurônios na primeira camada escondida. As saídas de cada camada oculta são multiplicadas por um novo conjunto de pesos, alimentado a próxima camada e sendo por fim direcionadas a m neurônios na camada de saída. Após aplicada uma função de ativação, são gerados y_m valores de probabilidade, como saída da rede.

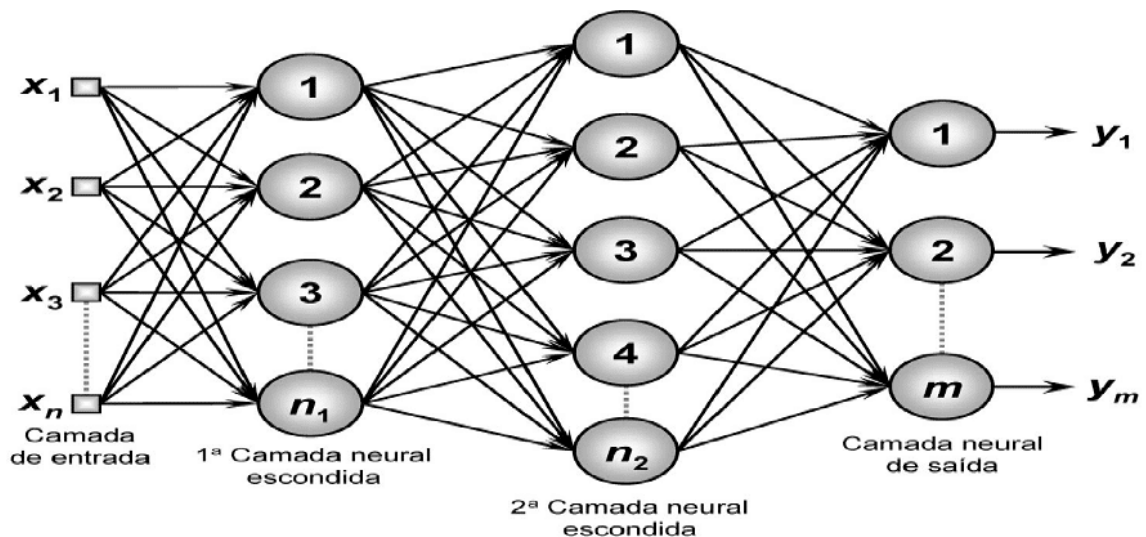


Figura 4 – Perceptron de múltiplas camadas.

2.6 Redes Neurais Convolucionais

A literatura considera que os principais conceitos das redes neurais convolucionais se deram pelo trabalho de [Hubel and Wiesel \(1962\)](#), que mostrou que os neurônios de alguns animais respondem individualmente a pequenas regiões do campo visual. Foi esse estudo que engajou vários outros trabalhos futuros até chegarmos recentemente na era do aprendizado profundo.

Em 1995, no trabalho de [LeCun et al. \(1995\)](#), os autores utilizaram esse estudo para arquitetar a primeira rede neural convolucional, em inglês *convolutional neural network* (CNN). O nome dado é justificado pelo fato de que a rede emprega uma operação matemática chamada convolução, que é um tipo especial de operação linear. CNNs são simplesmente redes neurais que usam a operação de convolução ([Bengio et al., 2017](#)).

De acordo com [Szegedy et al. \(2015\)](#) e [LeCun et al. \(2010\)](#), as CNNs são redes do tipo *feedforward* e tipicamente possuem as seguintes camadas em sua arquitetura: camadas convolucionais, camadas de subamostragem (ou *Pooling*) e camadas densas ou completamente conectadas, que podem ser dispostas de diversas formas a depender do problema abordado.

As camadas de convolução são responsáveis por extrair as características mais significativas da imagem. O processo de convolução é dado através da aplicação de extratores de características na imagem original. Uma das maiores vantagens da CNN em relação aos demais métodos de processamento digital de imagens é que nessa abordagem é possível obter os valores de extratores de características durante a etapa de treinamento da CNN, isto é, não se faz necessário a participação de um especialista para a escolha das características (atributos) de treinamento do modelo de classificação.

As camadas de subamostragem, também conhecidas como *Pooling*, segmentam as entradas das camadas anteriores em agrupamentos menores, reduzindo a sensibilidade da saída às pequenas variações e nuances da entrada de dados. Geralmente se aplica uma função de pool máximo nos dados de entrada da camada de subamostragem, uma vez que se espera obter as características mais relevantes da imagem.

No fim da arquitetura de uma CNN existe a camada de achatamento, que é responsável por redimensionar uma imagem 2D, em um vetor 1D, que posteriormente será entrada para algum classificador, seja uma rede perceptron multicamadas (MLP),

uma máquina de vetores de suporte (SVM), ou qualquer outro método que possua esse propósito. A Figura 5 ilustra um esquema de uma arquitetura de rede neural convolucional.

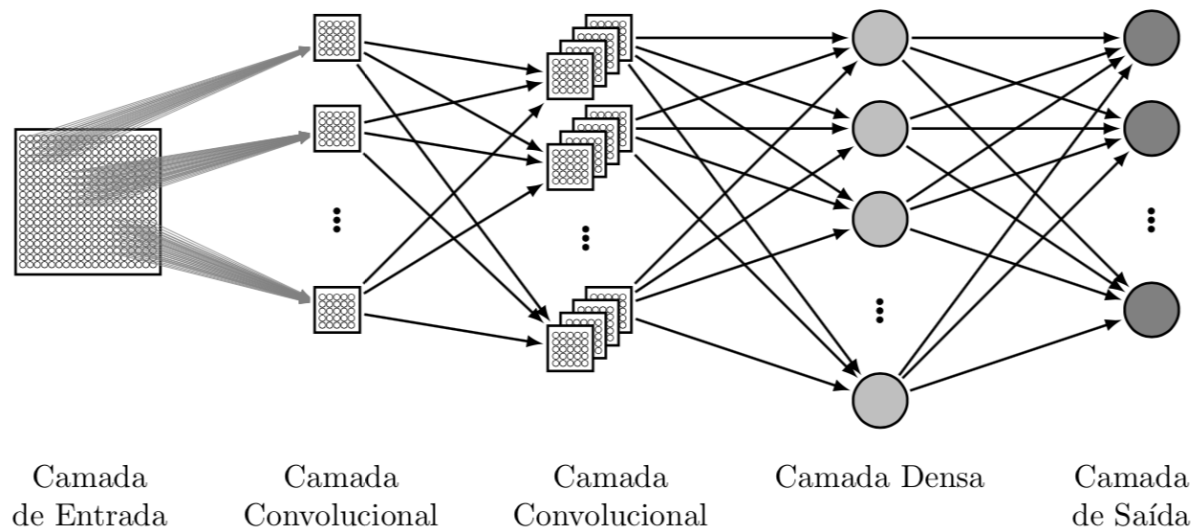


Figura 5 – Esquema de uma rede neural convolucional.

O treinamento de uma CNN é similar a outras técnicas mais simples de redes neurais artificiais (Bishop, 2006), uma vez que existe uma minimização da função de perda usando gradiente descendente. Desenvolver uma nova arquitetura de CNN para um problema específico não é trivial dada a dependência da configuração de cada camada e dos vários parâmetros do problema a ser resolvido.

A eficiência das CNNs no processo de reconhecimento de imagens é uma das principais razões pelas quais o mundo acordou para a eficácia da aprendizagem profunda. Atualmente, existem inúmeros centros de pesquisas que estão impulsionando grandes avanços na visão computacional, que tem aplicações bastante úteis para carros autônomos, robótica, drones, segurança, diagnósticos médicos e tratamentos para deficientes visuais.

Existem algumas arquiteturas de CNN consolidadas e pré-treinadas que são aplicadas a problemas de reconhecimento de imagens por meio do aprendizado de transferência, como a MobileNet (Howard et al., 2017), a Xception (Chollet, 2017) e a DenseNet (Huang et al., 2017). Neste trabalho, optou-se por realizar experimentos empíricos buscando encontrar os melhores parâmetros para definir a arquitetura da rede, uma vez que o problema a ser solucionado é bastante específico. As arquiteturas citadas pré-treinadas são utilizadas para classificar com sucesso diferentes tipos de objetos, como pessoas, carros, aviões, animais entre outros. Porém, nenhum desses objetos possui uma aparência semelhante aos ovos de parasitos abordados. Por isso, um dos objetivos do estudo foi encontrar uma

arquitetura de CNN que fosse adequada justamente para classificar as diferentes espécies de ovos.

2.7 Data Augmentation

Conforme dito por [Goodfellow et al. \(2016\)](#), técnicas de *deep learning* requerem milhares de dados para que seus modelos possam obter desempenhos satisfatórios. A escassez e o desbalanceamento de dados é um problema recorrente na área de *deep learning*, haja vista que uma grande parte dos problemas a serem resolvidos são extremamente difíceis ou até mesmo pode nem existir uma quantidade suficiente de dados para que o modelo a ser implementado possa ter o resultado esperado. Por isso, faz-se o uso de técnicas de *data augmentation*.

O aumento de dados abrange uma ampla gama de técnicas usadas para gerar novas amostras de treinamento a partir das originais, aplicando agitações e perturbações aleatórias (mas ao mesmo tempo garantindo que os rótulos de classe dos dados não sejam alterados). O principal objetivo ao aplicar o aumento de dados é aumentar a generalização do modelo.

No contexto da visão computacional, o aumento de dados é altamente recomendável, pois é possível novos dados a partir das imagens originais aplicando transformações geométricas simples, como: traduções, rotações, mudanças na escala, cisalhamento, inversões horizontais entre outras. A aplicação de transformações em uma imagem de entrada mudará sua aparência levemente mas não altera o rótulo da classe, tornando a ampliação de dados um método muito natural e fácil de ser aplicado para tarefas de aprendizado de máquina que incidem em imagens ([Perez and Wang, 2017](#)).

2.8 Métricas de Avaliação dos Resultados

Durante o processo de criação de um modelo de aprendizado de máquina é necessário que se meça a qualidade do mesmo em relação a sua eficiência em resolver determinada tarefa. Existem funções matemáticas que são qualificadas para avaliar a capacidade de erro e acerto de tal modelo, também chamadas de métricas.

Assim como é de extrema importância escolher um bom modelo para resolver tal

problema, também é necessário escolher uma métrica que seja capaz de avaliar o quão bom foi o desempenho do modelo proposto.

Existem dezenas de métricas disponíveis nessa etapa de avaliação, sendo algumas simples e outras mais complexas. Algumas métricas podem funcionar melhor para um determinado conjunto específico de dados enquanto outras se comportariam melhor em conjuntos de dados que possuem características diferentes.

Ao escolher uma métrica deve-se levar em consideração fatores como a proporção de dados de cada classe no conjunto de dados e o objetivo da classificação ou previsão (probabilidade, binário, ranking, etc). Por isso é importante conhecer bem a métrica que será utilizada, pois isso pode fazer toda a diferença no momento da avaliação do modelo. Nenhuma das métricas pode ser considerada melhor do que as outras em todos os casos. É sempre importante levar em conta a aplicação prática do modelo.

2.8.1 Matriz de Confusão

No problema de classificação estatística, na área do aprendizado de máquina, uma matriz de confusão é uma tabela que permite a visualização do desempenho de um modelo. Cada linha dessa tabela representa as instâncias de uma classe prevista, enquanto cada coluna ilustra as instâncias de uma classe real (Stehman, 1997).

Uma matriz de confusão é composta por quatro valores: verdadeiro positivo, falso negativo, falso positivo e verdadeiro negativo. Essa matriz é muito útil para a avaliação do modelo, uma vez que seus dados descrevem o resultado da classificação de cada registro, além de que é através dela que se torna possível encontrar as demais métricas, como acurácia, precisão, revocação e F1-score.

A Figura 6 ilustra um exemplo de uma matriz de confusão. Os quatro valores que compõem essa tabela são (Ting et al., 2011):

- **Verdadeiro positivo (VP):** indica a quantidade de registros que foram classificados como positivos corretamente, ou seja, a resposta do classificador foi que a entrada era positiva e a entrada realmente era positiva.
- **Verdadeiro negativo (VN):** indica a quantidade de registros que foram classificados como negativos de maneira correta, ou seja, a resposta do classificador foi que a

| | | PREDITO | |
|------------|----------|----------|----------|
| | | Classe A | Classe B |
| VERDADEIRO | Classe A | VP | FN |
| | Classe B | FP | VN |

Figura 6 – Exemplo da matriz de confusão.

entrada era negativa e a entrada realmente era negativa.

- **Falso positivo (FP):** indica a quantidade de registros que foram classificados como positivos de maneira incorreta, ou seja, a resposta do classificador foi que a entrada era positiva, mas a entrada era negativa.
- **Falso negativo (FN):** indica a quantidade de registros que foram classificados como entradas negativas de maneira incorreta, ou seja, a resposta do classificador foi que a entrada era negativa, mas a entrada era positivo.

2.8.2 Métricas de Qualidade

Com os valores obtidos por meio de uma matriz de confusão, torna-se possível encontrar as demais métricas, como acurácia, precisão, revocação e F1-score.

2.8.2.1 Acurária

A acurácia é o método mais simples de se calcular, sendo a divisão entre todos os acertos pelo total de exemplos. A Equação 2.1 ilustra como é realizado esse cálculo.

$$\frac{VP + VN}{VP + FP + FN + VN} \quad (2.1)$$

É necessário que o avaliador do modelo tome cuidado ao utilizar essa métrica, uma vez que a quantidade de dados de cada classe deve ser conhecida. Para essa pontuação significar algo, de fato, é necessário que a base de dados que foi utilizada para avaliação tenha uma boa variedade de resultados, não sendo um bom indicador para tarefas que possuam conjunto de dados desbalanceados.

2.8.2.2 Precisão (especificidade)

A precisão, também conhecida como especificidade, indica a relação entre os valores previstos positivos realizados corretamente e todas as previsões positivas, sendo as verdadeiras e as falsas. A Equação 2.2 enfatiza como é realizado esse cálculo.

$$\frac{VP}{VP + FP} \quad (2.2)$$

A métrica precisão fornece a informação sobre falsos positivos, em que trata-se de identificar um determinado resultado de maneira precisa. A principal utilização dessa métrica é para modelos onde é preciso minimizar os falsos positivos.

2.8.2.3 Revocação (sensibilidade)

A métrica revocação, também conhecida como sensibilidade, é utilizada para indicar a relação entre as previsões positivas realizadas corretamente e todas as previsões que realmente são positivas (verdadeiro positivo e falso negativo). A Equação 2.3 ilustra como é realizado esse cálculo.

$$\frac{VP}{VP + FN} \quad (2.3)$$

Essa métrica informa sobre os falsos negativos. Ela por si só não é diretamente vinculada a classificar todos os casos corretamente. Ela indica o quanto o modelo está identificando os casos positivos corretamente.

A revocação é bastante útil quando é necessário minimizar os falsos negativos. Ela é especialmente utilizada para casos de diagnósticos, em que pode haver um dano muito maior em não identificar uma doença, do que identificá-la em pacientes saudáveis. Sempre que for preciso minimizar os falsos negativos deve-se buscar uma maior pontuação nessa métrica.

2.8.2.4 F1-score

A métrica F1-score é uma maneira de se visualizar as métricas de precisão e de revocação juntas. O cálculo dessa métrica se dá através da média harmônica, uma vez que os valores calculados são iguais, em que se obtém resultados muito próximos da

média aritmética simples. No entanto, sempre que os valores são diferentes, essa média se aproxima mais dos valores menores. A Equação 2.4 enfatiza como é realizado esse cálculo.

$$\frac{2 \times precisao \times revocacao}{precisao + revocacao} \quad (2.4)$$

Em grande parte dos problemas, a F1-score é uma métrica melhor que a acurácia, principalmente em casos onde falsos positivos e falsos negativos possuem impactos diferentes para o modelo. Afinal, a F1-score cria um resultado a partir dessas divergências.

2.9 Estado da Arte

Na última década vários autores se dedicaram a estudar formas de automatizar esse processo de encontrar e classificar ovos em amostras fecais com o auxílio de um microscópio. Grande parte dos trabalhos até o momento se baseia na aplicação de métodos de processamento digital de imagens e reconhecimento de padrões, buscando encontrar características específicas de cada tipo de ovo de parasito para classificá-lo corretamente.

Yang et al. (2001) propõem em seu estudo um algoritmo utilizando técnicas de processamento digital de imagens e uma RNA. As características morfométricas de ovos de parasitos humanos em amostras fecais foram extraídas de imagens microscópicas através do processamento digital de imagens. Uma RNA classificou as espécies de parasitos com base nessas características. Os autores selecionaram quatro características morfométricas com base em três características morfológicas que representam forma, suavidade da concha e tamanho. Os resultados obtidos mostraram uma taxa de classificação correta média de 86,1% para a RNA-1 e 90,3% para a RNA-2.

No trabalho de Dogantekin et al. (2008) foi proposta uma técnica baseada em momentos invariantes de uma imagem, que permite calcular a área de um objeto, mesmo que tenha sofrido mudança de tamanho ou tenha sido rotacionado. Foram aplicados alguns métodos de processamento digital de imagens, como redução de ruído, aprimoramento de contraste, segmentação e processo morfológico, que foram utilizados na etapa de extração de características da abordagem usada neste estudo. A técnica apresentada neste trabalho permite classificar 16 diferentes ovos de parasitos a partir de suas imagens microscópicas. As simulações foram realizadas em computador comum no ambiente MATLAB e a taxa

geral de sucesso variou em torno de 95%.

Assim como [Dogantekin et al. \(2008\)](#), [Avci and Varol \(2009\)](#) também propõem uma metodologia baseada em momentos invariantes, combinando-a com a máquina de vetores de suporte multiclasse (MCSVM). O método proposto contém quatro estágios: pré-processamento, extração de recursos, classificação e teste. Foi utilizado o *software* MATLAB para estimar a taxa de classificação de sucesso da abordagem proposta. Para esse objetivo, o método foi avaliado usando dados do conjunto de teste. No final da avaliação, foi obtido uma taxa geral de sucesso de 97,70%.

No estudo de [Suzuki et al. \(2012\)](#) foi proposto um método capaz de segmentar e classificar, a partir de imagens de microscopia com impurezas fecais, as 15 espécies mais comuns de cistos de protozoários, ovos de helmintos e larvas no Brasil. A abordagem desenvolvida explora o formato dos objetos elipsoidais e a transformada imagem-floresta para segmentação de imagens. Os resultados indicam que o método implementado é uma abordagem promissora para a automação completa do diagnóstico de enteroparasitoses.

[Suzuki et al. \(2013\)](#) mencionam que, por mais que existam alguns métodos de identificação automática de ovos de parasitos, ainda existem algumas espécies que não obtiveram um índice aceitável de acerto, por isso, os autores propõem uma solução que visa automatizar o diagnóstico das 15 espécies mais comuns de enteroparasitos no Brasil, usando uma técnica parasitológica sensível, um microscópio motorizado com câmera digital para aquisição e foco automático de imagens e métodos de análise de imagens. Os resultados indicam que a solução proposta é eficaz e adequada para a rotina de laboratório, na qual o exame passa a ser concluído em alguns minutos.

[Nkamgang et al. \(2018\)](#) apresentam um sistema computacional que analisa automaticamente imagens microscópicas e consegue classificar parasitos intestinais. A abordagem é baseada na segmentação e treinamento de um classificador, utilizando a combinação de um sistema neuro-fuzzy e uma RNA. O parasito é primeiro localizado pela transformação circular de Hough e depois extraído para segmentação. Os resultados demonstram uma classificação com uma taxa de reconhecimento de 100% para cada uma das 20 classes de parasitos.

No estudo de [Nkamgang et al. \(2019\)](#) foi implementado um sistema médico especialista automatizado e útil para o diagnóstico da parasitose intestinal humana para

20 espécies. O *software* foi desenvolvido com base em um algoritmo de decisão. Uma base de conhecimento foi construída através de informações obtidas de livros e médicos, com informações referentes a cada doença causada por um parasito. O usuário interage com o sistema, respondendo a perguntas. As informações obtidas são cruzadas com um segundo método que utiliza a transformada circular de Hough e um classificador neuro-fuzzy treinado. O sistema foi avaliado com 60 casos de infecção e comparado ao diagnóstico de dois médicos especialistas. Foi obtido 58 diagnósticos corretos, correspondendo a uma precisão de 96,6%.

Tchinda et al. (2019) ofereceram uma solução para automatizar o diagnóstico de parasitos intestinais através de imagens obtidas de um microscópio conectado diretamente a um computador. A abordagem explora a detecção de contorno com base na transformação de *wavelets* em várias escalas para detectar o parasito. Os contornos ativos são combinados com a transformação Hough para realizar a segmentação e extração da imagem do parasito. A ferramenta de classificação é baseada em uma rede neural probabilística. O algoritmo desenvolvido foi testado em 900 amostras de imagens microscópicas de 15 espécies diferentes de parasitos intestinais. O resultado mostra uma taxa de reconhecimento de 100% de sucesso.

2.10 Resumo

Este capítulo descreveu o problema de interesse abordado nessa pesquisa, além de conceituar importantes termos imprescindíveis para a leitura e bom entendimento do trabalho. A utilização do método Kato-Katz na preparação das lâminas para o desenvolvimento do banco de imagens aqui abordado foi de extrema importância, além dos métodos de aprendizado de máquina empregados buscando resolver o problema proposto, em especial as redes neurais convolucionais. Foi discutido os resultados obtidos por outros autores sobre os estudos realizados na mesma temática desse trabalho. Dessa forma, o próximo capítulo tem como objetivo descrever a metodologia dessa pesquisa, citando o material e ferramentas utilizadas, e apresentando também todas as etapas metodológicas que foram aplicadas no decorrer de seu desenvolvimento.

Capítulo 3

Material e Métodos

O capítulo de Material e Métodos é um planejamento detalhado sobre o que foi realizado nessa pesquisa, de forma que o trabalho possa ser executado por outros pesquisadores, para a replicabilidade. Todas as etapas do processo foram descritas, desde a aquisição do conjunto de imagens até a validação dos modelos propostos através de experimentos e comparação de resultados.

A metodologia aplicada nessa pesquisa pode ser dividida nas etapas descritas no fluxograma ilustrado na Figura 7.

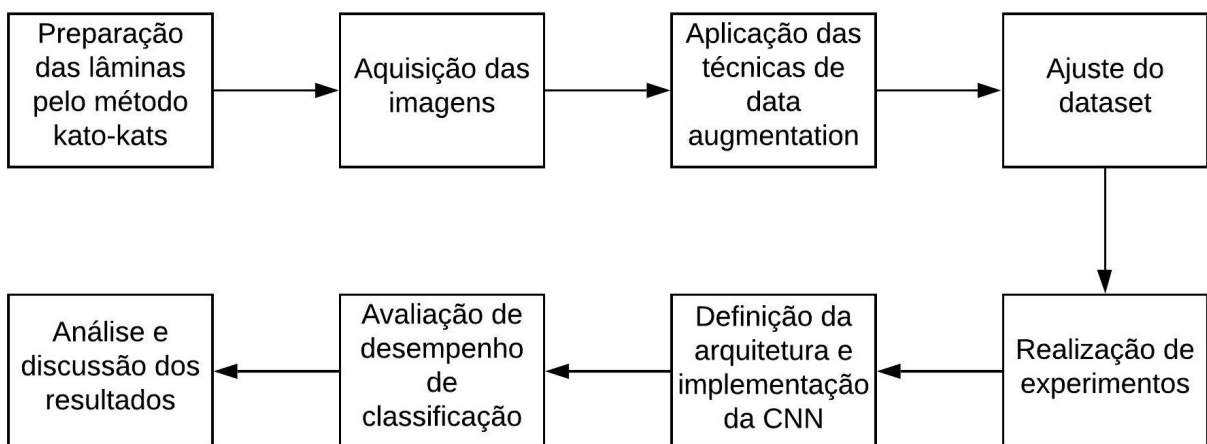


Figura 7 – Fluxograma do sistema proposto.

3.1 Criação do Dataset

Antes da execução do presente trabalho não havia na literatura um banco de imagens público dos ovos de parasitos das espécies aqui estudadas acessível para avaliação.

Com o auxílio do Laboratório de Imunologia de Helminhos no Instituto de Ciências Biológicas da Universidade Federal de Minas Gerais, preparou-se as lâminas pelo método Kato-Katz contendo amostras fecais que posteriormente foram levadas ao microscópio para serem examinadas. Foi utilizado um microscópio clínico da marca Olympus, modelo BX41, ajustado para um zoom de 100 vezes, tendo sido capturadas 66 imagens em RGB com resolução de 2048×1536 contendo ovos das seguintes espécies de parasitos: *Ancylostoma duodenale*, *Necator americanus*, *Ascaris lumbricoides*, *Enterobius vermicularis*, *Schistosoma mansoni* e *Trichuris trichiura*. A quantidade de imagens obtidas é justificada pelas amostras disponíveis no momento da coleta, enquanto os valores para o zoom e a resolução das imagens foram definidos de acordo com o que se é comumente utilizado nesse tipo de análise realizada pelos técnicos laboratoriais.

Vale ressaltar que os parasitos *Ancylostoma duodenale* e *Necator americanus* têm ovos indistinguíveis e, portanto, são referidos como Ancilostomídeos. Além disso, os ovos dos Ancilostomídeos não são preservados nas lâminas de Kato-Katz e seu conteúdo celular geralmente retrai algumas horas após a preparação. Os remanescentes são uma fina casca de ovo elíptica de material celular retraído, que parece com uma ‘meia-lua’. Outros ovos de helmintos frequentemente encontrados nas lâminas de Kato-Katz mostram estruturas e características morfológicas distintas e preservadas, que podem ser facilmente reconhecidas mesmo após semanas e meses de preparação.

Conforme descrito pela literatura, técnicas de *deep learning* exigem um conjunto de milhares de imagens para treinamento. Obtidas as imagens originais e sabendo que apenas 66 amostras pode acarretar em um desempenho que não faça sentido a utilização das técnicas de aprendizado profundo, optou-se por empregar operações de aumento de dados nessas imagens adquiridas. Ao se aplicar tais operações, é possível elevar a quantidade de imagens consideravelmente.

Para criar um conjunto representativo de imagens, com o auxílio de um script desenvolvido na linguagem de programação Python, todas as 66 imagens foram cortadas em imagens menores, com dimensões de 200×200 (exceto a espécie *Schistosoma mansoni*, que foi cortada com dimensões de 400×400 e posteriormente redimensionadas para dimensões de 200×200), tendo gerado aproximadamente, após a técnica de corte, 1000 imagens para cada classe. Em seguida, foram aplicadas rotações de 90° , 180° e 270° em cada uma dessas 1000 imagens e que foram separadas manualmente para cada classe.

Foram definidos somente esses ângulos para rotações com a justificativa de preservar a imagem em dimensão quadrada, sem que houvesse perda. Para finalizar, foi empregada a inversão horizontal na imagem original e em cada imagem rotacionada, obtendo-se ao final, após a utilização das operações de *data augmentation* para conseguir mais amostras, um total de 8000 imagens para cada classe das diferentes espécies de parasitos estudadas nesse trabalho. Se acreditou em um primeiro momento que essa quantidade de imagens fosse o suficiente para o treinamento de um modelo CNN e conseqüentemente que o mesmo fosse obter bons resultados no conjunto de teste para as métricas de avaliação ($> 99\%$).

A maior dificuldade dos especialistas que varrem essas amostras fecais em busca de classificar os ovos não está em saber identificar corretamente as diferentes espécies de helmintos, mas sim em confundir determinada morfologia de um ovo com alguma sujeira ou impureza contida na amostra fecal. Por esse motivo foram separadas 8000 imagens que não continham ovos de nenhuma espécie, apenas impurezas, para posteriormente avaliar um classificador binário entre uma determinada espécie e a classe sujeira. Para a classe sujeira, não foram aplicadas técnicas de rotação, essas imagens foram selecionadas após a técnica de corte sob a imagem original de resolução 2048×1536 .

A Figura 8 ilustra exemplos de imagens utilizadas no trabalho desenvolvido. Na primeira coluna, representada pela legenda X.1 estão as imagens originais cortadas. Na coluna representada pela legenda X.2 estão as imagens originais com uma rotação de 90° . Para a terceira e quarta coluna, a mesma imagem da primeira coluna tendo sido aplicada rotações de 180° e 270° , respectivamente. Da quinta à oitava coluna foi aplicado uma inversão horizontal em cada imagem das quatro colunas anteriores.

É possível observar, na Figura 8, que as linhas representam cada espécie de ovo de parasito sendo que na primeira linha são ovos de Ancilostomídeos, podendo ser das espécies *Ancylostoma duodenale* ou *Necator americanus*. Na segunda, terceira, quarta e quinta linha da Figura 8, tem-se ovos das espécies *Ascaris lumbricoides*, *Enterobius vermicularis*, *Schistosoma mansoni* e *Trichuris trichiura*, respectivamente. A última linha representada pela legenda F.X mostra imagens que não possuem ovos de nenhuma espécie de parasitos, mas que possuem impurezas que podem vir a confundir o especialista durante a análise na amostra de fezes do paciente.




Figura 8 – Exemplos de imagens contidas no conjunto de dados utilizado.

3.2 Definição da Arquitetura e Implementação da CNN

Esse estudo tem como objetivo avaliar o desempenho de uma CNN em classificar corretamente ovos de diferentes espécies de parasitos. Para isso, foi utilizado o ambiente de desenvolvimento Google Colab, que é um ambiente de notebook Jupyter gratuito e disponibilizado pela empresa Google LLC que não requer nenhum tipo de configuração e é executado inteiramente em nuvem com suporte para a linguagem de programação Python. O servidor utilizado nos experimentos de treinamento e validação dos modelos possui os seguintes recursos de *hardware*: um processador Xeon Processors @2.3Ghz i.e(1 núcleo, 2 *threads*), 12.6 GB disponível de memória RAM e 33 GB de memória para armazenamento em disco, além de uma GPU Tesla K80, possuindo 2496 núcleos CUDA e 12GB GDDR5 VRAM.

Para a implementação da arquitetura da CNN foi utilizada a biblioteca Keras em

sua versão 2.3.0, que possui implementado vários algoritmos de aprendizado de máquina de código aberto escritos em Python e tem como vantagem a capacidade de funcionar com o TensorFlow, o Microsoft Cognitive Toolkit, o Theano ou o PlaidML. Foi projetada para permitir a implementação rápida de algoritmos de *deep learning*, uma vez que tem como premissa facilitar o esforço do desenvolvedor, sendo uma biblioteca modulável e extensível (Chollet et al., 2015).

Foram implementadas duas diferentes arquiteturas de CNN. A primeira possui uma saída binária, sendo capaz de classificar a presença ou não do ovo de uma determinada espécie na imagem. O dataset utilizado nessa arquitetura foi composto em duas classes, sendo uma constituída por imagens que contém ovos de uma única determinada espécie de parasito e uma outra contendo imagens que não possuem nenhum ovo, apenas sujeiras e impurezas. Essa metodologia adotada é justificada pelo fato de que a maior dificuldade do especialista é na identificação dos ovos no meio da sujeira e impurezas em uma amostra fecal.

A segunda arquitetura foi implementada para um problema multiclasse de forma que o método consiga classificar corretamente entre todas as espécies abordadas nesse estudo, sendo elas: *Ancylostoma duodenale*, *Necator americanus*, *Ascaris lumbricoides*, *Enterobius vermicularis*, *Schistosoma mansoni* e *Trichuris trichiura*. Para essa arquitetura foram realizados experimentos utilizando arquiteturas pré-treinadas por meio do aprendizado por transferência, como a MobileNet (Howard et al., 2017), a Xception (Chollet, 2017) e a DenseNet (Huang et al., 2017). As camadas de convolução foram congeladas, atualizando somente os pesos das camadas ocultas do classificador.

Testes exaustivos e empíricos foram realizados variando os hiperparâmetros da CNN, como número de épocas, tamanho do lote de imagens, número de camadas de convolução, camadas de *Pooling*, número de extratores de características e seus respectivos tamanhos, utilização ou não de técnicas de regularização, como *Batch normalization*, *Dropout*, entre outros. Foram utilizadas arquiteturas pré-treinadas já consolidada no estado da arte, como a MobileNet (Howard et al., 2017), a Xception (Chollet, 2017) e a DenseNet (Huang et al., 2017), somente no problema de classificação multiclasse. Para o problema de classificação binária, optou-se por não utilizar o aprendizado por transferência, pelo fato de que o problema a ser solucionado é bastante específico e foi decidido realizar os experimentos dessa forma.

Foram realizados experimentos com diferentes combinações de hiperparâmetros para encontrar a melhor arquitetura de rede para o problema. As camadas de convolução, *Pooling* e camadas totalmente conectadas tiveram seus tamanhos variando entre 3 a 10. A quantidade de extratores de características em cada camada convolucional (8, 16, 32, 64 e 128), o número de neurônios nas camadas totalmente conectadas (8, 16, 32, 64, 128 e 256) e o tamanho dos filtros variaram em 3×3 , 5×5 e 9×9 . Além disso, o número de épocas para a convergência dos modelos foi de 1000.

3.3 Avaliação de Desempenho de Classificação

Para todos os experimentos, o dataset foi dividido aleatoriamente em três conjuntos: treinamento, validação e teste. De um total de 100% das imagens, o conjunto de treinamento conteve 80%, sendo 20% para o conjunto de teste. A quantidade de imagens contidas no conjunto de validação foi de 20% dentre as 80% sorteadas para o conjunto de treinamento. Para essa divisão foi utilizado o método *train_test_split* da biblioteca sklearn, que toma o cuidado de manter o balanceamento das classes durante a separação dos conjuntos de treinamento, validação e teste. Não existe uma regra para definir a quantidade de amostras que estará em cada um dos conjuntos, porém, os valores definidos são os mais praticados e encontrados nos trabalhos relacionados.

Para a análise dos resultados foram realizadas 30 (trinta) simulações para cada técnica proposta utilizando as métricas de avaliação já definidas, que são constantemente empregadas para avaliar modelos de classificação, sendo elas: acurácia, precisão, revocação e F1-score. Foi dado um peso maior ao parâmetro de revocação, pois para o problema estudado é importante que o máximo de ovos seja identificado corretamente, mesmo que haja uma baixa carga parasitária, afinal, é preferível que o classificador erre acusando um ovo em uma imagem que não contém ovo, do que errar acusando a não presença de um determinado ovo, quando na verdade existe um ovo na imagem.

A acurácia indica uma performance geral do modelo, uma vez que dentre todas as classificações, quantas o modelo classificou corretamente. A precisão é calculada através da verificação de quantas classificações estão corretas dentre todas da classe positiva que o modelo obteve. A revocação, também conhecida como sensibilidade ou recall, é obtida pela seguinte premissa: dentre todas as situações de classe positiva como valor esperado,

quantas estão corretas. A F1-Score é a média harmônica entre precisão e revocação.

3.4 Comparativo Entre Modelos

Sabe-se que o médico se utiliza dos sinais clínicos e o histórico individual de cada paciente para avaliar a necessidade de fazer o pedido de um teste diagnóstico para helmintíases. Com o histórico do paciente, o médico é capaz de direcionar a sua procura para uma determinada espécie de parasito, que é a principal razão do desenvolvimento do modelo de classificação binária. Pode acontecer de o médico não ter acesso a esse histórico do paciente, o que dificulta seu trabalho, uma vez que são iguais as chances de conter ovos de quaisquer espécies de helmintos em determinada amostra fecal.

Pensando nisso, foi realizado alguns ensaios com a arquitetura do problema de classificação multiclasse, em que após realizado o treinamento do modelo, esse foi experimentado com um conjunto de teste que continha apenas imagens de sujeiras e impurezas, onde não havia nenhum ovo de nenhuma espécie contida nesse banco de imagens. O modelo multiclasse sempre irá classificar as imagens de acordo com alguma classe e, posteriormente, a mesma imagem poderá ser utilizada no classificador binário específico para a classe dada pelo classificador multiclasse, que foi treinado para distinguir um ovo de uma determinada espécie em relação a sujeiras e impurezas contidas na imagem.

O objetivo ao se realizar estes experimentos foi de se chegar a seguinte conclusão: quando o médico não possui uma suspeita de qual a doença parasitária do paciente, o técnico laboratorial pode submeter a amostra ao modelo multiclasse, que dará como resultado o diagnóstico em uma das cinco classes de parasitos para qual foi treinado. Em seguida, para confirmar se realmente o modelo classificou corretamente, essa mesma amostra é submetida ao modelo binário específico para a classe rotulada pelo modelo multiclasse para, finalmente, confirmar se o paciente realmente está infectado (conforme predito pelo modelo multiclasse) ou se a amostra contém somente sujeira.

3.5 Resumo

Este capítulo descreveu os materiais e métodos utilizados nessa pesquisa. Primeiramente, criou-se o conjunto de imagens contendo ovos de diferentes espécies de parasitos.

Posteriormente, foi definida empiricamente a arquitetura do classificador binário e do classificador multiclasse, fazendo-se a implementação de cada modelo em seguida. Desenvolvido os classificadores, foi avaliado o desempenho de cada um, utilizando-se as métricas recomendadas na literatura, tanto para as arquiteturas definidas empiricamente quanto para as arquiteturas criadas utilizando o aprendizado por transferência. Para finalizar, foi realizado o comparativo entre os modelos binários e multiclasse, realizando experimentos de modo que ambos possam se comunicar, com o objetivo de que o sistema melhore seu desempenho. Dessa forma, o próximo capítulo tem como objetivo apresentar os resultados obtidos nesse trabalho, expondo as consequências da realização de cada etapa descrita na metodologia.

Capítulo 4

Resultados e Discussão

No capítulo de Resultados e Discussão são apresentadas as informações coletadas nessa pesquisa e a análise desses resultados obtidos. É relatado os hiperparâmetros escolhidos empiricamente das arquiteturas dos classificadores e os resultados obtidos utilizando as arquiteturas propostas, além da apresentação dos valores alcançados empregando aprendizado por transferência, com suas respectivas discussões.

4.1 Arquitetura da CNN

A partir da realização de alguns experimentos empíricos alternando alguns hiperparâmetros da rede neural convolucional foi possível encontrar uma determinada arquitetura de rede que obteve desempenho de classificação suficiente nas métricas avaliadas ($> 99\%$) no conjunto de teste, tanto para o problema binário quanto para o problema multiclasse, tendo assim duas arquiteturas diferentes.

A arquitetura da CNN que trata de um problema de classificação binária é composta por 03 (três) camadas convolucionais, 03 (três) camadas de subamostragem e 03 (três) camadas densas, sendo a ReLU (*rectified linear unit*) utilizada como função de ativação nas camadas convolucionais e a sigmóide logística na camada de saída. A primeira camada de convolução tem um total de 32 extratores de características, a segunda camada possui 64 extratores e para a terceira camada convolucional foi escolhido um total de 128 extratores, todos com tamanho de 3×3 , uma vez que os ovos representam um objeto específico e pequeno dentro da imagem. A técnica de *Batch Normalization* foi empregada nas camadas de convolução para normalizar os valores nos filtros para que o processamento

possa ser mais rápido.

Para as camadas densas foi escolhido uma quantidade de 128 neurônios para a primeira camada, seguido por 64 neurônios para a segunda camada e 32 para a terceira. A técnica de *Dropout* foi utilizada nas camadas densas zerando sempre aleatoriamente 20% da quantidade total dos valores desses neurônios de modo que a rede evite o excesso de ajuste e o modelo não fique super treinado. A Figura 9 ilustra a arquitetura da CNN escolhida para o problema binário.




Figura 9 – Arquitetura da CNN para o problema de classificação binário.

A arquitetura da CNN que trata de um problema de classificação multiclasse possui os mesmos hiperparâmetros da arquitetura para o problema de classificação binária nas camadas de convolução e de subamostragem. As arquiteturas se diferenciam nas camadas densas, uma vez que para o problema de classificação multiclasse foi necessário utilizar um total de 03 (três) camadas densas, contendo 128 neurônios em cada uma. A técnica de *Dropout* utilizada é responsável por zerar aleatoriamente 20% dos valores desses neurônios nas camadas densas. A Figura 10 ilustra a arquitetura da CNN escolhida para o problema multiclasse.

Os valores obtidos como o número de camadas de convolução, camadas de *Pooling*, número de extratores de características e seus respectivos tamanhos, utilização ou não de técnicas de regularização, como *Batch normalization*, *Dropout* foram definidos empiricamente baseados nos experimentos realizados e avaliados por meio das métricas de avaliação dos modelos de classificação.

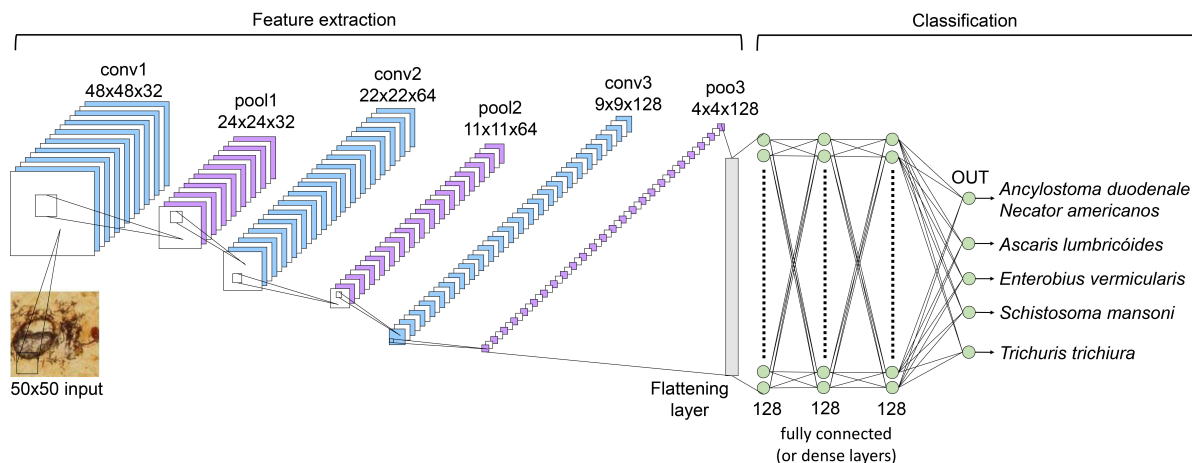


Figura 10 – Arquitetura da CNN para o problema de classificação multiclasse.

4.2 Experimentos Utilizando Arquiteturas Propostas

Para o problema de classificação binária, o dataset utilizado foi composto por oito mil imagens de determinada espécie e oito mil imagens pertencentes a classe sujeira. Já para o problema de classificação multiclasse foi utilizado um total de 40 mil imagens, sendo oito mil imagens para cada classe, que corresponde a cada espécie de parasito. Ressalta-se que os parasitos *Ancylostoma duodenale* e *Necator americanus* estão dentro do grupo dos Ancilostomídeos e seus ovos possuem a mesma morfologia, fazendo com que ambos pertençam a mesma classe.

Assim como feito por [Suzuki et al. \(2013\)](#), as simulações foram executadas 30 vezes com conjuntos aleatórios de treinamento, validação e teste. As Tabelas 1, 2, 3, 4 e 5 mostram a média e o desvio padrão de cada experimento levando em consideração a acurácia, precisão, revocação e F1-score, utilizando a arquitetura definida para o problema binário.

Tabela 1 – Resultados dos experimentos realizados com os ovos do grupo dos Ancilostomídeos.

| | Impurezas | Ancilostomídeos |
|------------------|-----------------------|-----------------------|
| Acurácia | 99.90% σ 0.003 | |
| Precisão | 100% σ 0 | 100% σ 0 |
| Revocação | 99.70% σ 0.005 | 99.70% σ 0.005 |
| F1-score | 99.90% σ 0.003 | 99.90% σ 0.003 |

As pesquisas citadas na seção de trabalhos relacionados alcançaram resultados expressivos ($> 90\%$) na classificação de ovos de algumas espécies de parasitos. Grande

Tabela 2 – Resultados dos experimentos realizados com os ovos da espécie *Ascaris lumbricoides*.

| | Impurezas | <i>Ascaris lumbricoides</i> |
|------------------|-----------------------|-----------------------------|
| Acurácia | 100% σ 0 | |
| Precisão | 100% σ 0 | 99.93% σ 0.002 |
| Revocação | 99.96% σ 0.001 | 100% σ 0 |
| F1-score | 99.98% σ 0.001 | 99.95% σ 0.002 |

Tabela 3 – Resultados dos experimentos realizados com os ovos da espécie *Enterobius vermicularis*.

| | Impurezas | <i>Enterobius vermicularis</i> |
|------------------|-----------------------|--------------------------------|
| Acurácia | 99.26% σ 0.008 | |
| Precisão | 99.46% σ 0.014 | 99.13% σ 0.007 |
| Revocação | 99.13% σ 0.008 | 99.50% σ 0.014 |
| F1-score | 99.26% σ 0.008 | 99.26% σ 0.009 |

Tabela 4 – Resultados dos experimentos realizados com os ovos da espécie *Schistosoma mansoni*.

| | Impurezas | <i>Schistosoma mansoni</i> |
|------------------|-----------------------|----------------------------|
| Acurácia | 98.63% σ 0.016 | |
| Precisão | 98.63% σ 0.025 | 98.63% σ 0.019 |
| Revocação | 98.63% σ 0.021 | 98.63% σ 0.027 |
| F1-score | 98.60% σ 0.017 | 98.63% σ 0.016 |

Tabela 5 – Resultados dos experimentos realizados com os ovos da espécie *Trichuris trichiura*.

| | Impurezas | <i>Trichuris trichiura</i> |
|------------------|-----------------------|----------------------------|
| Acurácia | 100% σ 0 | |
| Precisão | 100% σ 0 | 99.66% σ 0.004 |
| Revocação | 99.63% σ 0.004 | 100% σ 0 |
| F1-score | 99.78% σ 0.004 | 99.8% σ 0.004 |

parte deles utilizaram técnicas de processamento digital de imagens buscando extrair características da morfologia dos ovos para cada espécie. Os resultados obtidos ilustrados nas Tabelas 1, 2, 3, 4 e 5 demonstram a eficiência ($> 98\%$) em utilizar redes neurais convolucionais para o problema em questão.

Ao se avaliar o valor de revocação médio para uma determinada espécie de ovo de parasito em cada experimento, foi obtida uma taxa de acerto de 100% para o grupo dos Ancilostomídeos, 100% para o parasito *Ascaris lumbricoides*, 99.50% para *Enterobius vermicularis*, 98.63% para a espécie *Schistosoma mansoni* e uma taxa de 100% de acerto para a classificação correta dos ovos da espécie *Trichuris trichiura*.

A justificativa de uma maior importância na avaliação do algoritmo proposto para a métrica de revocação é o fato de que, para diagnósticos médicos, o número de falsos negativos deve tender a zero, uma vez que um diagnóstico falso em relação a não doença de um determinado paciente doente, pode levar ao desenvolvimento e evolução dessa enfermidade e até mesmo ocasionar sua morte.

O estudo feito levando em consideração um problema de classificação binária, em que buscou classificar corretamente ovos de uma determinada espécie em meio de uma amostra fecal que contém milhares de impurezas e sujeiras, é de extrema relevância para essa pesquisa.

Considerando o problema multiclasse, ao observar a Tabela 6, é possível concluir que a arquitetura de CNN proposta para esse determinado problema conseguiu classificar os ovos das espécies de parasitos abordadas, tendo obtido valores de acurácia, precisão, revocação e F1-score próximos de 100% (diferença menor que 0.5%), independentemente da espécie.

Tabela 6 – Resultados dos experimentos realizados com os ovos de todas as espécies estudadas nessa pesquisa.

| | Acurácia | Precisão | Revocação | F1-score |
|--------------------------------|--------------------------|--------------------------|--------------------------|--------------------------|
| Ancilomídeos | | 99.63% σ 0.010 | 100% σ 0 | 99.86% σ 0.004 |
| <i>Ascaris lumbricoides</i> | | 100% σ 0 | 100% σ 0 | 100% σ 0 |
| <i>Enterobius vermicularis</i> | 99.46% σ 0.021 | 99.66% σ 0.011 | 98.16% σ 0.059 | 98.80% σ 0.034 |
| <i>Schistosoma mansoni</i> | | 99.90% σ 0.005 | 99.66% σ 0.010 | 99.76% σ 0.006 |
| <i>Trichuris trichiura</i> | | 98.80% σ 0.038 | 99.56% σ 0.013 | 99.16% σ 0.020 |

Ressalta-se que para todas as 30 simulações realizadas com cada modelo, tanto para os problemas de classificação binária quanto o problema de classificação multiclasse, os resultados alcançados por meio das métricas de avaliação foram praticamente iguais, resultando num desvio padrão próximo de zero (diferença menor que 0.05%) entre esses resultados, o que valida as arquiteturas propostas. Isso quer dizer que, independente da divisão aleatória das imagens nos conjunto de treino, validação e teste, os modelos após treinados conseguiram classificar corretamente os ovos de parasitos contidos nas imagens de teste.

Para atribuir importância ao modelo do problema multiclasse e conectá-lo ao modelo de classificação binária, o mapa de calor ilustrado pela Figura 11 apresenta o experimento realizado em que o modelo multiclasse foi treinado com todas as imagens das cinco espécies de parasitos abordadas nesse trabalho, em que obteve um valor próximo de 100% (diferença menor que 0.5%) para todas as métricas avaliadas. Posteriormente esse modelo foi submetido a um conjunto de testes que continha quatro mil imagens de sujeiras e impurezas, e que não continham ovos de nenhuma espécie de helminto.




Figura 11 – Mapa de calor que representa a classificação de cada uma das 4000 imagens de sujeira submetidas a arquitetura multiclasse.

O mapa de calor apresentado na Figura 11 representa a saída prevista do modelo

para cada imagem, que estão representadas pelas linhas, de acordo com cada valor obtido após a probabilidade dada pela função de ativação softmax, ou seja, cada valor numérico ilustrado mais a esquerda da Figura 11 representa a identificação de uma imagem que continha apenas sujeiras. Como foram submetidas quatro mil imagens, os valores variam entre 0 a 3999. Para cada imagem, que também é a entrada da rede implementada para o problema multiclasse, seus valores são processados e, ao final, é gerado um valor de probabilidade por meio da função de ativação softmax, que representa o grau de confiança da rede em classificar tal espécie de parasito.

Também na Figura 11, é possível observar uma coluna de variação de cor do preto ao branco, no canto direito da Figura 11, além de que na parte inferior da mesma Figura 11 é apresentado valores que variam de 0 a 4, um para cada espécie de parasito. Com isso, tem-se a seguinte relação: para cada imagem submetida, o modelo classificou a amostra em uma determinada espécie (representada pela cor branca, que é uma probabilidade mais próxima ao valor 1 de ser de determinada classe), enquanto as demais espécies receberam uma probabilidade baixa, ilustrada pela cor preta.

O modelo sempre deveria classificar em uma das cinco classes disponíveis, e o que ficou evidenciado com o mapa de calor foi que na maioria das vezes a classificação dada com maior probabilidade foi para a classe 0, 2 ou 3, representadas pelos ovos das espécies Ancilostomídeos, *Enterobius vermicularis* e *Schistosoma mansoni*, respectivamente.

Acredita-se que o modelo multiclasse tenha aprendido características não apenas da morfologia dos ovos das espécies Ancilostomídeos, *Enterobius vermicularis* e *Schistosoma mansoni*, mas também possivelmente de alguns outros aspectos de sujeira em volta dos ovos. Isso fez com que houvesse uma incidência maior de probabilidade dessas classes para que uma determinada imagem que continha apenas sujeiras e impurezas, fosse classificada como uma dessas três espécies, uma vez que muito provavelmente o modelo possa ter confundido algumas características contidas em uma determinada imagem de sujeira e que se parecia com as características extraídas da morfologia do ovo.

O modelo multiclasse deve ser utilizado em casos em que o especialista, por algum motivo, não tenha o histórico de vida anterior do paciente, podendo utilizar tal modelo para verificar a qual classificação pertence determinada amostra, para que posteriormente, feito essa primeira classificação, utilize o modelo indicado para verificar se realmente existe

um ovo de helminto daquela determinada classe sugerida pelo modelo multiclasse, ou se era apenas sujeira.

Como o modelo multiclasse conseguiu aproximadamente 100% (diferença menor que 0.5%) nas métricas avaliadas, acredita-se que se realmente conter um ovo de helminto na amostra analisada, o modelo irá conseguir classificá-lo corretamente. Caso a amostra contenha apenas sujeiras ou impurezas, o modelo irá direcionar tal amostra para que, posteriormente, o especialista utilize o modelo binário para correta classificação, em casos em que o especialista não possua o histórico do paciente.

4.3 Experimentos Utilizando Transfer Learning

A Tabela 7 apresenta os resultados alcançados na classificação de ovos de parasitos para o problema multiclasse, utilizando arquiteturas pré-treinadas por meio do aprendizado por transferência. As redes empregadas foram a MobileNet (Howard et al., 2017), a Xception (Chollet, 2017) e a DenseNet (Huang et al., 2017). As camadas de convolução foram congeladas, atualizando somente os pesos das camadas ocultas do classificador.

Com a Tabela 7 percebe-se que os resultados obtidos foram insuficientes ($< 90\%$). As MobileNets são baseadas em uma arquitetura simplificada que utiliza convoluções separáveis em profundidade para criar redes neurais profundas e leves, muito utilizadas em sistemas embarcados devido sua quantidade reduzida de parâmetros. Para o problema abordado nessa pesquisa, ficou provado que a adoção dessa arquitetura na solução do problema apresenta resultados nas métricas de avaliação insuficiente ($< 90\%$).

Para as arquitetura pré-treinadas Xception e DenseNet foi percebida uma melhora em relação a MobileNet, porém, ainda assim, muito longe de um resultado que permita sua empregabilidade. Os modelos classificaram corretamente poucas das vezes e, consequentemente, da forma que estão, não poderiam ser utilizados em uma aplicação real para esse problema que envolve diagnóstico de doenças com imagens médicas.

Os resultados obtidos utilizando o aprendizado por transferência com essas determinadas redes já pré-treinadas demonstraram que para o conjunto de dados empregado, elas obtiveram resultados na métricas de avaliação insuficientes ($< 90\%$), o que justifica a proposta de uma nova arquitetura de rede. Se acredita que tais redes não conseguiram resultados nas métricas de avaliação ($> 90\%$) justamente pelo fato de que se trata de um

Tabela 7 – Resultados dos experimentos utilizando transfer learning.

| | Model | Accuracy | Precision | Recall | F1-score |
|--------------------------------|------------|--------------------------|--------------------------|--------------------------|--------------------------|
| Hookworms | MobileNets | 9.39% σ 0.089 | 1.66% σ 0.091 | 0% σ 0 | 0% σ 0 |
| | Xception | 35.49% σ 0.028 | 7.56% σ 0.062 | 0.16% σ 0.003 | 0.43% σ 0.005 |
| | DenseNet | 28.84% σ 0.029 | 18.13% σ 0.040 | 27.63% σ 0.115 | 21.50% σ 0.061 |
| <i>Ascaris lumbricoides</i> | MobileNets | 9.39% σ 0.089 | 17.13% σ 0.356 | 0.10% σ 0.005 | 0.002% σ 0.009 |
| | Xception | 35.49% σ 0.028 | 28.76% σ 0.034 | 99.63% σ 0.010 | 44.63% σ 0.040 |
| | DenseNet | 28.84% σ 0.029 | 30.93% σ 0.037 | 99.99% σ 0.003 | 47.20% σ 0.042 |
| <i>Enterobius vermicularis</i> | MobileNets | 9.39% σ 0.089 | 5.66% σ 0.078 | 16.40% σ 0.340 | 7.06% σ 0.125 |
| | Xception | 35.49% σ 0.028 | 72.06% σ 0.177 | 1.96% σ 0.016 | 3.80% σ 0.030 |
| | DenseNet | 28.84% σ 0.029 | 86.93% σ 0.057 | 15.23% σ 0.124 | 24.10% σ 0.154 |
| <i>Schistosoma mansoni</i> | MobileNets | 9.39% σ 0.089 | 7.50% σ 0.252 | 1.06% σ 0.058 | 0.60% σ 0.032 |
| | Xception | 35.49% σ 0.028 | 93.83% σ 0.050 | 4.56% σ 0.025 | 8.63% σ 0.044 |
| | DenseNet | 28.84% σ 0.029 | 3.33% σ 0.182 | 0% σ 0 | 0% σ 0 |
| <i>Trichuris trichiura</i> | MobileNets | 9.39% σ 0.089 | 15.23% σ 0.155 | 31.16% σ 0.446 | 13.13% σ 0.155 |
| | Xception | 35.49% σ 0.028 | 59.50% σ 0.100 | 70.96% σ 0.130 | 63.30% σ 0.058 |
| | DenseNet | 28.84% σ 0.029 | 93.33% σ 0.253 | 0.76% σ 0.008 | 1.50% σ 0.014 |

problema bastante específico, em que os extratores de características já treinados para classificar outros objetos, não conseguiram generalizar para o problema abordado.

4.4 Resumo

Neste capítulo foram apresentados os resultados e discussões dos experimentos realizados com os modelos desenvolvidos. No próximo capítulo, foram descritas as conclusões encontradas após desenvolvimento desta pesquisa, bem como os trabalhos futuros que podem vir a ser desenvolvidos a partir dessas conclusões.

Capítulo 5

Conclusões

Nessa dissertação foi apresentada uma nova solução baseada em CNN para automatizar a detecção e o diagnóstico de cinco tipos de ovos de helmintos frequentemente encontrados em fezes humanas, examinados pelo método de esfregaço espesso de Kato-Katz, são elas: *Ancylostoma duodenale*, *Necator americanus*, *Ascaris lumbricoides*, *Enterobius vermicularis*, *Schistosoma mansoni* e *Trichuris trichiura*.

O método utilizado para a classificação de ovos de parasitos em imagens de microscopia óptica foram as Redes Neurais Convolucionais, em que foi definida empiricamente a melhor arquitetura para os dois problemas propostos, o de classificação binária e o de classificação multiclasse.

Um ponto relevante que pode ser observado nesse trabalho foi a utilização das operações de *data augmentation*, pois, graças a sua empregabilidade, foi possível usufruir de técnicas do aprendizado profundo. Em grande parte dos problemas que existem na área médica, assim como o desse estudo, é praticamente impossível que se tenha um número grande o suficiente de dados para que possa trabalhar com algoritmos de *deep learning*. Devido a isso, utilizar essas operações de aumento de dados se torna imprescindível e pertinente para que se consiga resultados promissores.

Foram definidas duas arquiteturas de CNN. A primeira conseguiu diferenciar os ovos de determinada espécie das impurezas contidas em uma lâmina fecal, demonstrando sua eficiência. Para todos os modelos, foram obtidos resultados de 99.9% nas métricas avaliadas. A segunda conseguiu classificar cada ovo de espécies diferentes com uma taxa de acerto de 99.9%, apesar da semelhança morfológica entre algumas espécies.

Os resultados obtidos demonstraram uma classificação de 99.9% nas métricas de avaliação para os problemas abordados. É importante ressaltar que o método pode ser estendido a um número maior de espécies de helmintos e a diferentes métodos de detecção, seguindo procedimentos semelhantes.

As Redes Neurais Convolucionais podem ser utilizadas para outros casos que contenham imagens biomédicas, como ressonância magnética de mamografia, imagens de microscópio ou de satélites. Portanto, esse trabalho representa uma contribuição significativa para automatizar o diagnóstico de doenças humanas intestinais e serve como embasamento para a aplicação de arquiteturas de CNNs em outros problemas.

5.1 Trabalhos Futuros

O objetivo final desse trabalho foi proporcionar um algoritmo baseado em CNN que sirva como base para o desenvolvimento de um sistema computacional totalmente automatizado para a análise de amostras fecais, podendo ser aplicado no Sistema Único de Saúde (SUS). Dois diferentes tipos de sistemas são possíveis. Um sistema *online* em que o microscópio é conectado a um servidor remoto e com isso, o servidor possa ter acesso a imagem e conseguir fazer a detecção dos ovos. Além disso, uma opção alternativa seria um sistema embarcado totalmente acoplado ao microscópio óptico que poderia realizar a detecção dos ovos de forma automática. O algoritmo apresentado nesse trabalho será parte essencial de um futuro sistema que permitirá automatizar a detecção de ovos de parasitos para o diagnóstico em exames fecais.

Como foi descrito no decorrer do trabalho, os resultados obtidos demonstraram uma classificação de 99.9% nas métricas de avaliação para os problemas abordados. Contudo, esse desempenho foi avaliado em uma situação controlada, sendo necessário que se realize uma validação real em uma amostra da população, de preferência, em áreas endêmicas onde se haja suspeita de uma alta taxa de infectados.

Referências

- Alpaydin, E. (2014). Introduction to machine learning/ethem alpaydin.
- Assis, S., Oliveira, B., Sasaki, R., and Santos, F. (2019). Desenvolvimento de um protótipo para classificação de perfis de pulverização utilizando processamento digital de sinais e redes neurais artificiais. *Revista Brasileira de Computação Aplicada*, 11(1):14–27.
- Avci, D. and Varol, A. (2009). An expert diagnosis system for classification of human parasite eggs based on multi-class svm. *Expert Systems with Applications*, 36(1):43–48.
- Barbosa, C. S., Gomes, E. C. S., Marcelino, J. M. R., Cavalcante, K. R., and Nascimento, W. R. C. (2017). Quality control of the slides by kato-katz method for the parasitological diagnosis of schistosomiasis infection by schistosoma mansoni. *Jornal Brasileiro de Patologia e Medicina Laboratorial*, 53(2):110–114.
- Barreto, J. M. (2002). Introdução às redes neurais artificiais. *Florianópolis: UFSC*.
- Bengio, Y., Goodfellow, I., and Courville, A. (2017). *Deep learning*, volume 1. Citeseer.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. springer.
- Castoril, B. R., Oliveira, B. A. S., Assis, S. S., Morais, B. R., and Santos, F. H. W. (2018). Previsão de demanda de energia elétrica no setor de produção do laticínio do ifmg campus bambuí utilizando regressão de vetores de suporte. *Revista de Informática Aplicada*, 14(2).
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1251–1258.
- Chollet, F. et al. (2015). Keras.

- De Carli, G. A. (2001). Parasitologia clínica: seleção de métodos e técnicas de laboratório para diagnóstico das parasitoses humanas. In *Parasitologia clínica: seleção de métodos e técnicas de laboratório para diagnóstico das parasitoses humanas*, page 810. Atheneu: São Paulo.
- Deng, L., Yu, D., et al. (2014). Deep learning: methods and applications. *Foundations and Trends® in Signal Processing*, 7(3–4):197–387.
- Dogantekin, E., Yilmaz, M., Dogantekin, A., Avci, E., and Sengur, A. (2008). A robust technique based on invariant moments–anfis for recognition of human parasite eggs in microscopic images. *Expert Systems with Applications*, 35(3):728–738.
- Erhan, D., Bengio, Y., Courville, A., Manzagol, P.-A., Vincent, P., and Bengio, S. (2010). Why does unsupervised pre-training help deep learning? *Journal of Machine Learning Research*, 11(Feb):625–660.
- Flores, J. H. F. (2009). Comparação de modelos mlp/rna e modelos box-jenkins em séries temporais não lineares. *Porto Alegre: UFRGS*.
- Gomes, T. C., Almeida, M. F., Miura, L. A., Granja, J., Santos, D. V., Oliveira, R. M., Lopes, A., Sequeira, B. P., Rolemberg, A. A., Moraes, A. L., et al. (2002). Helmintosos intestinais em população de rua da cidade do rio de janeiro. *Rev Soc Bras Med Trop*, 35(5):531–2.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- Hecht-Nielsen, R. (1992). Theory of the backpropagation neural network. In *Neural networks for perception*, pages 65–93. Elsevier.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708.
- Hubel, D. H. and Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat’s visual cortex. *The Journal of physiology*, 160(1):106–154.

- Katz, N., Chaves, A., Pellegrino, J., et al. (1972). A simple device for quantitative stool thick-smear technique in schistosomiasis mansoni. *Rev Inst Med Trop Sao Paulo*, 14(6):397–400.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pages 1097–1105.
- Kucik, C. J., Martin, G. L., and Sortor, B. V. (2004). Common intestinal parasites. *American family physician*, 69(5).
- LeCun, Y., Bengio, Y., et al. (1995). Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, 3361(10):1995.
- LeCun, Y., Kavukcuoglu, K., and Farabet, C. (2010). Convolutional networks and applications in vision. In *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, pages 253–256. IEEE.
- Michie, D., Spiegelhalter, D. J., Taylor, C., et al. (1994). Machine learning. *Neural and Statistical Classification*, 13.
- Mohammadzadeh, I., Rostami, A., Darvish, S., Mehravar, S., Pournasrollah, M., Javanian, M., Dooki, M. E., and Gamble, H. R. (2019). Exposure to ascaris lumbricoides infection and risk of childhood asthma in north of iran. *Infection*, 47(6):991–999.
- Neves, D. P. (2003). Parasitologia dinâmica. In *Parasitologia dinâmica*, page 212. Atheneu: São Paulo.
- Nkamgang, O. T., Tchiotsop, D., Fotsin, H. B., Talla, P. K., Dorr, V. L., and Wolf, D. (2019). Automating the clinical stools exam using image processing integrated in an expert system. *Informatics in Medicine Unlocked*, 15:100165.
- Nkamgang, O. T., Tchiotsop, D., Tchinda, B. S., and Fotsin, H. B. (2018). A neuro-fuzzy system for automated detection and classification of human intestinal parasites. *Informatics in Medicine Unlocked*, 13:81–91.
- Nunes, G. H., Oliveira, B. A. S., and Nametala, C. A. L. (2020). A computational strategy for classification of enem issues based on item response theory. *Revista de Informática Teórica e Aplicada*, 27(1):92–111.

- Oliveira, B. A. S., Nametala, M. S., Castoril, B. R., Catalano, M. D., and Nametala, C. A. L. (2018). Avaliação de uma rede neural artificial como estimador temporal pluviométrico no sistema de abastecimento cantareira. *Revista de Informática Aplicada*, 14(1).
- Pan, S. J. and Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10):1345–1359.
- Perez, L. and Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*.
- Rosenberg, C., Hebert, M., and Schneiderman, H. (2005). Semi-supervised self-training of object detection models. *WACV/MOTION*, 2.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61:85–117.
- Stehman, S. V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote sensing of Environment*, 62(1):77–89.
- Suzuki, C. T., Gomes, J. F., Falcao, A. X., Papa, J. P., and Hoshino-Shimizu, S. (2012). Automatic segmentation and classification of human intestinal parasites from microscopy images. *IEEE Transactions on biomedical Engineering*, 60(3):803–812.
- Suzuki, C. T., Gomes, J. F., Falcao, A. X., Shimizu, S. H., and Papa, J. P. (2013). Automated diagnosis of human intestinal parasites using optical microscopy images. In *2013 IEEE 10th International Symposium on Biomedical Imaging*, pages 460–463. IEEE.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1–9.
- Tarafder, M., Carabin, H., Joseph, L., Balolong Jr, E., Olveda, R., and McGarvey, S. (2010). Estimating the sensitivity and specificity of kato-katz stool examination technique for detection of hookworms, ascaris lumbricoides and trichuris trichiura infections in humans in the absence of a ‘gold standard’. *International journal for parasitology*, 40(4):399–404.

- Tchinda, B. S., Noubom, M., Tchiotsop, D., Louis-Dorr, V., and Wolf, D. (2019). Towards an automated medical diagnosis system for intestinal parasitosis. *Informatics in Medicine Unlocked*, page 100238.
- Ting, K. M., Sammut, C., and Webb, G. (2011). Encyclopedia of machine learning. *KM Ting.*—Boston, MA: Springer.
- WHO (2018). Working to overcome the global impact of neglected tropical diseases: first who report on neglected tropical diseases. Technical report, Geneva: World Health Organization.
- WHO (2020). Weekly epidemiological record, 2020, vol. 95, 22 [full issue]. *Weekly Epidemiological Record= Relevé épidémiologique hebdomadaire*, 95(22):241–256.
- Yang, Y. S., Park, D. K., Kim, H. C., Choi, M.-H., and Chai, J.-Y. (2001). Automatic identification of human helminth eggs on microscopic fecal specimens using digital image processing and an artificial neural network. *IEEE Transactions on Biomedical Engineering*, 48(6):718–730.