

**UNIVERSIDADE NOVE DE JULHO – UNINOVE**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO**  
**CONHECIMENTO**

**RAFAEL OLIVEIRA COTRIN**

**MÉTODO BASEADO EM APRENDIZAGEM DE MÁQUINA PARA DETECÇÃO DE**  
**PEQUENAS PORÇÕES D'ÁGUA EM IMAGENS MULTIESPECTRAIS**  
**ADQUIRIDAS POR DRONES**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Informática e Gestão do Conhecimento da UNINOVE como parte dos requisitos para obtenção do título de Mestre em Informática.

São Paulo

2023

**UNIVERSIDADE NOVE DE JULHO – UNINOVE**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO**  
**CONHECIMENTO**

**RAFAEL OLIVEIRA COTRIN**

**MÉTODO BASEADO EM APRENDIZAGEM DE MÁQUINA PARA DETECÇÃO DE**  
**PEQUENAS PORÇÕES D'ÁGUA EM IMAGENS MULTIESPECTRAIS**  
**ADQUIRIDAS POR DRONES**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Informática e Gestão do Conhecimento da UNINOVE como parte dos requisitos para obtenção do título de Mestre em Informática.

Orientador: Prof. Dr. Sidnei A. de Araújo

Linha de pesquisa: LP2 – Sistemas Inteligentes

São Paulo  
2023



### **PARECER – EXAME DE DEFESA**

Parecer da Comissão Examinadora designada para o exame de defesa do Programa de Pós-Graduação em Informática e Gestão do Conhecimento a qual se submeteu o aluno Rafael Oliveira Cotrin.

Tendo examinado o trabalho apresentado para obtenção do título de “Mestre em Informática e Gestão do Conhecimento”, com Dissertação intitulada “MÉTODO BASEADO EM APRENDIZAGEM DE MÁQUINA PARA DETECÇÃO DE PEQUENAS PORÇÕES D'ÁGUA EM IMAGENS MULTIESPECTRAIS ADQUIRIDAS POR DRONES”, a Comissão Examinadora considerou o trabalho:

☒ ( X ) Aprovado

☐ ( ) Aprovado condicionalmente

☐ ( ) Reprovado com direito a novo exame

☐ ( ) Reprovado

### **EXAMINADORES**

Prof. Dr. Sidnei Alves de Araújo - PPGI/Uninove (Orientador)

\_\_\_\_\_

Prof. Dr. Sergio Vicente Denser Pamboukian - Universidade Presbiteriana Mackenzie (Membro Externo)

\_\_\_\_\_

Prof. Dr. Peterson Adriano Belan - PPGI/UNINOVE (Membro Interno)

\_\_\_\_\_

São Paulo, 17 de agosto de 2023

Cotrin, Rafael Oliveira.

Método baseado em aprendizagem de máquina para detecção de pequenas porções d'água em imagens multiespectrais adquiridas por drones. / Rafael Oliveira Cotrin. 2023.

71 f.

Dissertação (Mestrado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2023.

Orientador (a): Prof. Dr. Sidnei Alves de Araújo.

1. RPA. 2. Drone. 3. Mosquito. 4. Aedes aegypt. 5. Água. 6. Aprendizagem de máquina.

I. Araújo, Sidnei Alves de. II. Título.

CDU 004

## DEDICATÓRIA

Dedico este trabalho à minha esposa Valéria Cotrin e  
à minha filha Milena Cotrin, pelo apoio e  
compreensão nos momentos em que não  
pude acompanhá-las devido às  
tarefas da pesquisa.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus por ter me concedido saúde e sabedoria na condução desta pesquisa.

À minha esposa Valéria, minha filha Milena, minha família e amigos por todo o amor, apoio, carinho e incentivo à qual me proporcionaram em todos os momentos.

Ao meu orientador, Prof. Dr. Sidnei Alves de Araújo, por todo o conhecimento disponibilizado, tempo dedicado, apoio e paciência, pois independente das circunstâncias, não mediu esforços para me orientar, certamente sem essa dedicação, acredito que muitas coisas não seriam assertivas como foram.

A todos os professores do corpo docente do PPGI, em especial aos professores, Alessandro, Cleber, Felipe, Peterson e Wonder, pelos conselhos passados e ensinamentos transmitidos.

Ao Prof. Dr. Sergio V. D. Pamboukian, coordenador do LABGEO e ao Renato técnico do LABGEO, pelo apoio na aquisição das imagens nos dois dias de experimentos realizados na Universidade Presbiteriana Mackenzie, sem essa grande parceria, não teria sido possível a realização dos experimentos.

Aos colegas de mestrado e doutorado, Eli, Saulo, Sabrina, Robson e em especial ao Gustavo, que me apoiou em momentos importantes do trabalho, inclusive na aquisição de imagens e experimentos.

A Universidade Nove de Julho pela bolsa de mestrado fornecida e ferramentas disponibilizadas. Assim como a CAPES pela bolsa de auxílio concedida.

Por fim, a todos que me acompanharam em todo o período e contribuíram de alguma forma para que esse título de mestre fosse possível através da pesquisa conduzida.

## RESUMO

Os RPAS – *Remotely Piloted Aircraft System*, popularmente conhecidos como drones, vêm sendo utilizados para identificar automaticamente objetos e cenários (normalmente caixas d'água, baldes, vasos de plantas, e outros recipientes contidos em lixo a céu aberto) que caracterizam potenciais criadouros de mosquitos, como o *Aedes aegypt*, a partir das imagens adquiridas. Contudo, apesar de se saber que água parada é uma condição essencial para a procriação de mosquitos, os sistemas de visão computacional (SVCs) propostos na literatura para análise automática das imagens não incluem a detecção de água nos objetos e cenários suspeitos, o que constitui uma limitação técnica para a utilização efetiva dos drones nas ações de monitoramento e controle de vetores. Neste trabalho é proposto um método que emprega uma Rede Neural Artificial do tipo *Multilayer Perceptron* (RNA-MLP) para identificação de pequenas porções de água em imagens multiespectrais adquiridas por drones. Para a realização dos experimentos foi composta uma base contendo 151 imagens multiespectrais de 1280×960 pixels, que estão divididas em dois conjuntos e que foram adquiridas a partir de cenários simulados contendo pequenos recipientes com e sem água em um ambiente controlado. Os resultados obtidos pelo método proposto (precisão média de 0.759) corroboram seu potencial para incrementar a viabilidade técnica dos SVCs existentes, tornando-os mais efetivos no combate aos focos de mosquitos, o que pode trazer contribuições para a área de saúde pública.

**Palavras-chave:** RPA, Drone, Mosquito, *Aedes aegypt*, Água, Aprendizagem de máquina.

## **ABSTRACT**

RPAS – Remotely Piloted Aircraft System, popularly known as drones, are used to automatically identify objects and scenarios (normally water tanks, buckets, plant pots, and other containers contained in open-air trash) that characterize potential mosquito breeders, such as *Aedes aegypt*, from the acquired images. However, despite knowing that water stagnation is an essential condition for mosquito breeding, computer vision systems (SVCs) proposed in the literature for automatic image analysis do not include the detection of water in suspicious objects and scenarios, which constitutes a technical limitation for the effective use of drones in vector monitoring and control actions. In this work, a method is proposed that employs an Artificial Neural Network of the Multilayer Perceptron type (RNA-MLP) to identify small portions of water in multispectral images acquired by drones. To carry out the experiments, a database was composed containing 151 multispectral images of 1280×960 pixels, which are divided into two sets and were acquired from simulated scenarios containing small containers with and without water in a controlled environment. The results obtained by the proposed method (average precision of 0.759) corroborate its potential to increase the technical solutions of existing SVCs, making them more effective in combating mosquito outbreaks, which can bring contributions to the area of public health.

**Keywords:** RPA, Drone, Mosquito, *Aedes aegypt*, Water, Machine Learning

## LISTA DE FIGURAS

|                                                                                                                                            |    |
|--------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1: Identificação de corpos d'água a partir de imagens de satélite utilizando o IIA. ....                                            | 27 |
| Figura 2: Assinaturas espectrais da água, solo e vegetação .....                                                                           | 28 |
| Figura 3: Diferenças entre as bandas espectrais e níveis de refletância de sensores acoplados em satélites e a câmera RedEdge MX .....     | 28 |
| Figura 4: Hierarquia clássica de aprendizado .....                                                                                         | 29 |
| Figura 5: Classes de arquiteturas de RNAs .....                                                                                            | 31 |
| Figura 6: Exemplo de arquitetura MLP com camadas ocultas .....                                                                             | 33 |
| Figura 7: Exemplos de classificação linear utilizando SVM.....                                                                             | 34 |
| Figura 8: Exemplos de classificação não linear utilizando SVM.....                                                                         | 35 |
| Figura 9: Exemplo de classificação com algoritmo K-NN.....                                                                                 | 36 |
| Figura 10: Distribuição dos objetos e suas capacidades de armazenamento em litros. (a) conjunto 1; (b) conjunto 2 .....                    | 38 |
| Figura 11: Bandas espectrais de uma imagem do Conjunto 1 – Cenário 3. (a) blue; (b) green; (c) red; (d) Infra-red (d); (e) RedEdge;.....   | 39 |
| Figura 12: Comparação dos modelos de classificação e de regressão nos experimentos preliminares.....                                       | 40 |
| Figura 13: Correlações entre as bandas espectrais das imagens.....                                                                         | 41 |
| Figura 14: Visualização dos dados no espaço PCA (com 3 atributos) .....                                                                    | 41 |
| Figura 15: Diagrama do funcionamento do método proposto .....                                                                              | 42 |
| Figura 16: Posição e identificação espacial dos sensores da câmera RedEdge MX                                                              | 43 |
| Figura 17: Ajustes das imagens para adequada seleção da ROI.....                                                                           | 44 |
| Figura 18: Imagem combinando as bandas RGB após ajustes e recorte .....                                                                    | 44 |
| Figura 19: Exemplo de imagem anotada indicando as ROIs .....                                                                               | 45 |
| Figura 20: Esquema completo para montagem do arquivo de treinamento e teste ..                                                             | 46 |
| Figura 21: Classificação dos pixels de uma imagem pela RNA-MLP .....                                                                       | 48 |
| Figura 22: Exemplos de resultados da RNA treinada com o (Conjunto 1) .....                                                                 | 52 |
| Figura 23: Exemplos de resultados da RNA treinada com o (Conjunto 2) .....                                                                 | 54 |
| Figura 24: Exemplos de resultados da RNA treinada com o (Conjunto Unificado) ...                                                           | 57 |
| Figura 25: Falhas nas classificações dos pixels devido à problemas de iluminação do ambiente – Treinamento com imagens do Conjunto 1 ..... | 59 |

|                                                                                                                                         |    |
|-----------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 26: Falhas nas classificações dos pixels devido à problemas de iluminação do ambiente – Treinamento com conjunto unificado ..... | 59 |
| Figura 27: Diferença de tamanhos de recipientes dos conjuntos 1 e 2 .....                                                               | 60 |
| Figura 28: Acoplamento do método proposto neste trabalho em um SVC para detecção de objetos e cenários suspeitos .....                  | 61 |

## LISTA DE TABELAS

|                                                                                                        |    |
|--------------------------------------------------------------------------------------------------------|----|
| Tabela 1: Cenários do Conjunto 1.....                                                                  | 38 |
| Tabela 2: Cenários do Conjunto 2.....                                                                  | 39 |
| Tabela 3: Resultados dos algoritmos de regressão e de classificação nos experimentos preliminares..... | 40 |
| Tabela 4: Resultados obtidos pela RNA MLP treinada com o Conjunto 1 .....                              | 51 |
| Tabela 5: Matriz de confusão – imagem MICA_CEN01_V1 .....                                              | 53 |
| Tabela 6: Resultados obtidos pela RNA MLP treinada com o Conjunto 2 .....                              | 53 |
| Tabela 7: Matriz de confusão – imagem MICA_CEN01_V1 .....                                              | 55 |
| Tabela 8: Resultados obtidos pela RNA MLP dos conjuntos 1 e 2 unificados .....                         | 56 |

## LISTA DE ABREVIATURAS E SIGLAS

|         |                                                                              |
|---------|------------------------------------------------------------------------------|
| AD      | Árvores de Decisão                                                           |
| ADA     | <i>AdaBoost</i>                                                              |
| AG      | Algoritmos Genéticos                                                         |
| AM      | Aprendizagem de Máquina                                                      |
| ANATEL  | Agência Nacional de Telecomunicações                                         |
| API     | <i>Application Programming Interface</i>                                     |
| CASA    | <i>Civil Aviation Safety Authority</i>                                       |
| CNN     | <i>Convolutional Neural Network</i>                                          |
| EASA    | <i>European Aviation Safety Agency</i>                                       |
| EDG     | <i>RedEdge</i>                                                               |
| FAA     | <i>Federal Aviation Administration</i>                                       |
| FN      | Falso Negativo                                                               |
| FP      | Falso Positivo                                                               |
| GEE     | <i>Google Earth Engine</i>                                                   |
| GeoOBIA | <i>Geographic Object-Based Image Analysis</i>                                |
| IA      | Inteligência Artificial                                                      |
| IIA     | Índice Indicador de Água                                                     |
| KNN     | <i>K-Nearest Neighbors Classifier</i>                                        |
| MCP     | Modelo de rede neural proposto por <i>Warren S. McCulloch e Walter Pitts</i> |
| MDS     | Modelo Digital de Superfície                                                 |
| MDT     | Modelo Digital de Terreno                                                    |
| MH      | Meta-Heurística                                                              |
| MLP     | <i>Multilayer Perceptron</i>                                                 |
| MS      | Ministério da Saúde do Brasil                                                |
| NDVI    | <i>Normalized Difference Vegetation Index</i>                                |
| NDWI    | <i>Normalized Difference Water Index</i>                                     |

|        |                                                                   |
|--------|-------------------------------------------------------------------|
| NIR    | <i>Near-Infrared</i> (infravermelho próximo)                      |
| OBJ    | Objetos                                                           |
| OMS    | Organização Mundial de Saúde                                      |
| PCA    | <i>Principal Component Analysis</i>                               |
| RBAC-E | Regulamento Brasileiro de Aviação Civil Especial                  |
| RF     | <i>Random Forest</i>                                              |
| RGB    | Espaço de cor (R: <i>red</i> , G: <i>green</i> e B: <i>blue</i> ) |
| RNA    | Rede Neural Artificial                                            |
| RNC    | Rede Neural Convolucional                                         |
| ROI    | <i>Region of interest</i> (região de interesse)                   |
| RPAS   | <i>Remotely Piloted Aircraft System</i>                           |
| SARPAS | Solicitação de Acesso de Aeronaves Remotamente Pilotadas          |
| SISANT | Sistema de Aeronaves não Tripuladas                               |
| SR     | Sensoriamento Remoto                                              |
| SSIM   | <i>Structural Similarity Index</i>                                |
| SVM    | <i>Support Vector Machine</i>                                     |
| VIS    | Espectro visível                                                  |
| VN     | Verdadeiro Negativo                                               |
| VP     | Verdadeiro Positivo                                               |

## SUMÁRIO

|                                                                                                                                                      |           |
|------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>1 INTRODUÇÃO .....</b>                                                                                                                            | <b>16</b> |
| 1.1 CONTEXTUALIZAÇÃO DO TEMA.....                                                                                                                    | 16        |
| 1.2 TRABALHOS CORRELATOS E LACUNA DE PESQUISA.....                                                                                                   | 18        |
| 1.3 OBJETIVOS .....                                                                                                                                  | 22        |
| 1.3.1 <i>Objetivo Geral</i> .....                                                                                                                    | 22        |
| 1.3.2 <i>Objetivos Específicos</i> .....                                                                                                             | 22        |
| 1.4 MOTIVAÇÃO E JUSTIFICATIVA .....                                                                                                                  | 23        |
| <b>2 FUNDAMENTAÇÃO TEÓRICA .....</b>                                                                                                                 | <b>25</b> |
| 2.1 MOSQUITO AEDES AEGYPTI: DOENÇAS TRANSMITIDAS, CICLO DE VIDA, HÁBITOS, LOCAIS DE PROLIFERAÇÃO E INSPEÇÃO DE POTENCIAIS CRIADOUROS NO BRASIL ..... | 25        |
| 2.2 CARACTERIZAÇÃO DE ÁGUA EM IMAGENS DIGITAIS .....                                                                                                 | 26        |
| 2.3 APRENDIZAGEM DE MÁQUINA .....                                                                                                                    | 29        |
| 2.3.1 Redes Neurais Artificiais (RNA) .....                                                                                                          | 31        |
| 2.3.1.1 <i>Redes Neurais Artificiais Multilayer Perceptron (RNA-MLP)</i> .....                                                                       | 32        |
| 2.3.2 <i>Support Vector Machines (SVM)</i> .....                                                                                                     | 33        |
| 2.3.3 <i>Nearest Neighbors Classification (K-NN)</i> .....                                                                                           | 35        |
| 2.3.4 <i>Random Forest (RF)</i> .....                                                                                                                | 36        |
| <b>3 MATERIAL E MÉTODO .....</b>                                                                                                                     | <b>37</b> |
| 3.1 BASE DE IMAGENS .....                                                                                                                            | 37        |
| 3.2 EXPERIMENTOS PRELIMINARES PARA DEFINIÇÃO DO ALGORITMO DE AM EMPREGADO NO MÉTODO PROPOSTO .....                                                   | 40        |
| 3.3 MÉTODO DE AM PROPOSTO .....                                                                                                                      | 42        |
| 3.3.1 <i>Segmentação e anotação das imagens</i> .....                                                                                                | 43        |

|                                                                                                                          |           |
|--------------------------------------------------------------------------------------------------------------------------|-----------|
| 3.3.2 Extração de características, transformação de dados e composição dos conjuntos de treinamento e teste da RNA ..... | 45        |
| 3.3.3 Treinamento e teste da RNA .....                                                                                   | 47        |
| 3.3.4 Classificação dos pixels da imagem usando a RNA treinada.....                                                      | 48        |
| 3.4 PROCEDIMENTOS PARA CONDUÇÃO DOS EXPERIMENTOS E AVALIAÇÃO DO MÉTODO PROPOSTO.....                                     | 48        |
| <b>4 RESULTADOS E DISCUSSÃO .....</b>                                                                                    | <b>51</b> |
| 4.1 RESULTADOS OBTIDOS COM A RNA-MLP TREINADA COM OS DADOS DOS CONJUNTOS 1 E 2 ISOLADOS.....                             | 51        |
| 4.2 RESULTADOS OBTIDOS COM A RNA-MLP TREINADA COM OS DADOS DOS CONJUNTOS 1 E 2 UNIFICADOS .....                          | 56        |
| 4.3 DISCUSSÃO .....                                                                                                      | 58        |
| <b>5 CONCLUSÕES E PROPOSTA PARA TRABALHO FUTUROS .....</b>                                                               | <b>62</b> |
| <b>REFERÊNCIAS.....</b>                                                                                                  | <b>64</b> |

## 1 INTRODUÇÃO

Este capítulo apresenta primeiramente a contextualização do tema investigado nesta pesquisa (seção 1.1). Na sequência são apresentados trabalhos correlatos da literatura e as lacunas de pesquisa (seção 1.2). Na seção 1.3 são descritos os objetivos. Por fim, na seção 1.4, apresenta-se a justificativa para proposição do método de aprendizagem.

### 1.1 CONTEXTUALIZAÇÃO DO TEMA

Nos últimos anos têm sido registrados números cada vez maiores de casos de doenças causadas por mosquitos, como o *Aedes aegypti*, que é o principal vetor da dengue, chikungunya e a zika. Para a Organização Mundial de Saúde (OMS), isso é um motivo de preocupação, pois segundo dados levantados, a incidência da doença cresceu consideravelmente nas últimas duas décadas, chegando a mais de 4,2 milhões de casos em mais de 130 países, ou seja, aproximadamente metade da população mundial corre risco de contágio, com uma estimativa de que cerca de 100 a 400 milhões de pessoas podem contrair dengue a cada ano (OMS, 2023; ONU, 2023).

Nas Américas, mais de 3,1 milhões de casos foram notificados até o mês de julho de 2023, sendo cerca de 80% (2,6 milhões de casos) somente no Brasil (PAHO, 2023). Segundo o Ministério da Saúde (MS), até maio de 2023 ocorreram no Brasil 1.379.893 casos prováveis de dengue, com taxa de incidência de 647 casos por 100 mil habitantes, com 635 óbitos confirmados. Se comparado ao mesmo período de 2022, houve um aumento de 22% no número de casos. Com relação à chikungunya, foram notificados 118.448 casos prováveis (taxa de incidência de 56 casos por 100 mil habitantes), sendo as maiores taxas apresentadas nas regiões nordeste e sudeste. No que tange a zika, foram notificados 8.413 casos prováveis no país, levando a uma taxa de incidência de 4 casos/100 mil habitantes (MS, 2023).

A quantidade de casos de doenças causadas pelo mosquito *Aedes aegypti* só demonstra como é importante identificar formas para minimizar a sua proliferação, pois o aumento do número de notificações está correlacionado a um maior gasto para os municípios (DANTAS, 2021). Atualmente existem diversas ações de prevenção e controle, as quais envolvem o governo federal, os governos estaduais e municipais, agentes de saúde e a comunidade.

A prevenção e controle do mosquito pode ser operacionalizada através de quatro ações: 1. Prevenção da reprodução do mosquito. 2. Proteção individual contra picadas de mosquito. 3. Envolvimento da comunidade. 4. Vigilância ativa de vírus e mosquitos (OMS, 2021). Essa última é incentivada pela OMS visando a criação de ferramentas inovadoras ou novos métodos de gestão para identificação de vetores e intervenções sustentáveis, eficazes e adaptadas para o contexto atual (OMS, 2023). Não obstante, o uso inovador da tecnologia para combater focos de mosquitos pode contribuir para o atingimento dos Objetivos de Desenvolvimento Sustentável (ODS) estabelecidos na agenda 2030 da Organização das Nações Unidas (ONU).

Segundo o MS (2022d), os reservatórios para armazenamento de água de uso doméstico como as caixas d'água, tambores e baldes são vistos como potenciais criadouros de mosquitos. Além desses reservatórios, vasos de plantas, pneus, calhas, assim como recipientes contidos em lixo a céu aberto podem conter pequenas porções de água e, portanto, também são considerados potenciais focos larvais. Ocorre que, quando existe água parada em algum desses itens mencionados, a suspeita de possível foco larval é aumentada, visto que essa é uma condição essencial para o mosquito se desenvolver e procriar.

Para conter a proliferação dos mosquitos, somente no ano de 2023 (até de junho), foram utilizados 15 milhões de inseticidas em pastilhas, 33 mil litros para fumacê e aproximadamente 57 mil quilos de inseticidas em pó, a maior parte aplicada em objetos com água armazenada (MS, 2023).

Quando os assuntos são relacionados a proteção individual e a participação da comunidade, normalmente são realizadas ações populares como campanhas através das mídias sociais, distribuições de panfletos em áreas mais propensas a surtos. Tudo isso para explicar à população que o envolvimento das pessoas é uma medida relevante para contenção do aumento de casos de doenças causadas pelo *Aedes aegypti*, pois os objetos e cenários na maioria das vezes ficam em locais residenciais e como os acessos são restritos aos agentes de saúde, isso acaba dificultando as ações que dependem apenas do governo (MS, 2022c).

No campo do sensoriamento remoto (SR), os satélites comumente empregados para monitoração terrestre podem ser empregados em soluções que visam o combate aos focos de mosquitos. Contudo, as baixas resoluções espacial e temporal são fatores que limitam suas utilizações nesta tarefa, mesmo considerando satélites mais modernos como o WorldView-4. Assim, os drones têm surgido como excelentes

alternativas em tarefas de sensoriamento remoto, já que possibilitam voos mais próximos ao solo obtendo imagens com altas resoluções espacial e temporal (CARRASCO-ESCOBAR *et al.*, 2019; DINIZ e MEDEIROS, 2018; e PASSOS *et al.*, 2018).

Nesse contexto, os drones têm sido um grande aliado na identificação dos focos de mosquitos. Nos últimos anos têm sido propostos diversos sistemas de visão computacional (SVCs) para identificação automática de objetos e cenários que caracterizam potenciais focos de mosquitos a partir de imagens adquiridas com o uso de drones, tais como Bravo *et al.* (2021), Passos *et al.* (2020) e Rossi, Backes e Souza (2020).

Contudo, apesar de se saber que água parada propicia a proliferação de mosquitos, tais sistemas normalmente não detectam a existência de água nos objetos e cenários identificados nas imagens. Apenas alguns poucos trabalhos, como Bravo *et al.* (2019); Bravo (2019) e Prasad (2015), exploraram essa questão, mas as soluções apresentadas em tais trabalhos ainda estão longe de contemplar as reais necessidades.

Portanto, um método que possa detectar pequenas porções d'água pode incrementar a viabilidade técnica dos SVCs existentes, como por exemplo os propostos em Agarwal *et al.* (2014); Mehra *et al.* (2016); Bravo *et al.* (2021); Passos *et al.* (2020) e Rossi, Backes e Souza (2020), aumentando a efetividade do uso de drones no combate aos focos de mosquitos, como mencionado em Cotrin *et al.* (2022). Neste trabalho denominam-se pequenas porções d'água, a água contida em pequenos objetos como baldes, vasos de plantas, e outros recipientes normalmente contidos em lixo a céu aberto, os quais são mencionados em documentos do MS e são normalmente considerados nos estudos da literatura.

## 1.2 TRABALHOS CORRELATOS E LACUNA DE PESQUISA

Existem vários trabalhos na literatura da última década propondo o uso de drones para identificação automática de objetos e cenários que caracterizam potenciais focos de mosquitos, entre os quais podemos citar: Agarwal *et al.* (2014), Bravo *et al.* (2021); Dias *et al.* (2018); Hardy *et al.* (2019); Mehra *et al.* (2016); Passos *et al.* (2018); Passos *et al.* (2020); Rossi, Backes e Souza (2020) e F Trujillano *et al.* (2023).

Nesses trabalhos normalmente são levados em conta os principais objetos suspeitos como caixas d'água, pneus, piscinas, vasos de plantas, calhas, além de lixo inorgânico a céu aberto. Alguns poucos desses trabalhos mencionam detecção de pequenas porções de água, como Mehra *et al.* (2016) e Dias *et al.* (2018), entretanto, os experimentos conduzidos em tais trabalhos não demonstram isso.

Há também trabalhos que exploram o uso de drones para identificação de potenciais focos de mosquitos a partir de características de corpos d'água como braços de mares, rios e lagos, tais como os trabalhos de AMARASINGHE e WIJESURIYA (2020), CARRASCO-ESCOBAR *et al.* (2019); HAAS-STAPLETON *et al.* (2019); MINAKSHI *et al.* (2020); STANTON *et al.* (2021) e SUDUWELLA *et al.* (2017).

Amarasinghe e Wijesuriya (2020) apresentaram um sistema para controle de reprodução de mosquitos baseado em imagens coletadas por drone. Criaram dois algoritmos para identificar água estagnada utilizando características das imagens e com isso identificar de forma automática focos dos mosquitos. Os autores conseguiram em seus experimentos uma acurácia acima de 81% no primeiro algoritmo e 91% com o segundo. Os dois algoritmos são baseados em técnicas de processamento de imagem e aprendizado de máquina, nos quais foram utilizados para treinamento e testes apenas as bandas RGB (*Red*, *Green* e *Blue*), sendo que, apenas com as informações dessas bandas não é possível distinguir se existe água ou não nos locais suspeitos.

Carrasco-Escobar *et al.* (2019) exploraram o uso de drones no mapeamento de corpos d'água baseando-se em imagens multiespectrais de alta resolução discriminando características de corpos d'água na região da Amazônia Peruana. Os experimentos conduzidos utilizaram 31 corpos d'água entre artificiais e naturais, como viveiros de peixes, riachos, córregos e pântano. As imagens foram classificadas com aprendizagem supervisionada e algoritmo de árvore de decisão na ferramenta *Google Earth Engine* (GEE), onde foi obtido uma acurácia média de 87% a 97% na identificação de corpos d'água. Apesar disso, o estudo não levou em consideração a identificação de pequenas porções de água contidas em pequenos recipientes, e o uso da ferramenta (GEE) para realizar a classificação, traz limitações tanto em conectividade com internet, quanto no custo de utilização e licença de uso.

Haas-Stapleton *et al.* (2019) propuseram a utilização de drone equipado com uma câmera multiespectral de alta resolução para quantificar e mapear água

acumuladas em superfície de um pântano de maré na Baía de São Francisco (EUA), para classificar de forma automática a identificação de larvas de mosquitos. No total os autores coletaram 17.836 imagens multiespectrais, nas quais para identificar as características de água utilizaram o software *SlantView*. Para quantificação de quantidade de larvas e pupas foi utilizado o software MATLAB AI com *Deep Learning, Image Processing and Computer Vision Toolboxes*. Para classificação automática das larvas foi utilizada uma rede neural convolucional sendo empregada a *AlexNet Convolutional Neural Network (CNN)*. Os resultados obtidos tiveram uma acurácia de 94,1% na classificação de larvas e 52,8% para pupas. Os autores não disponibilizaram o banco de imagens; apresentaram um software utilizado na agricultura para identificação de porções d'água, e os softwares empregados inviabilizam a criação de um sistema de baixo custo pois ambos possuem licença de utilização.

Minakshi *et al.* (2020) conduziram um estudo para validar o uso de drones para otimizar o mapeamento preditivo de potenciais criadouros de mosquitos da malária, baseado em assinaturas de corpos d'água através das bandas RGB e multiespectrais das imagens coletadas. Também propuseram disponibilizar os ortomosaicos das localizações dos potenciais focos em um aplicativo para utilidade pública. Foi empregada classificação supervisionada utilizando a ferramenta do *Google Earth Engine (GEE)* e o treinamento do modelo com as imagens RGB com *Faster (Faster R-CNN)*. Embora os resultados tenham sido promissores, os autores abordaram apenas identificação de poças d'água e não disponibilizaram o banco de imagens descrito no trabalho. A utilização da ferramenta (GEE) para realizar classificação traz limitações no que está relacionado às essas técnicas, possuindo limitações para customizações, assim como em conectividade com internet, custo e licença de utilização. Além do fato de que utilizaram o indicador NDVI para as imagens multiespectrais o qual é utilizado para analisar medições de sensoriamento remoto a partir de uma plataforma espacial, o que não garante a mesma aplicabilidade para sensores levados a bordo de drones.

Stanton *et al.* (2021) realizaram um experimento para identificar criadouros de larvas de mosquitos da malária a partir de coleta de imagens através de drones. O experimento teve como foco a identificação de corpos d'água e vegetação aquática, a qual os autores utilizaram métodos manuais e análise de imagens de objetos geográficos baseado em *Geographic Object-Based Image Analysis (GeoOBIA)* e utilizaram o algoritmo *LargeScaleMean-Shift* disponível no software de código aberto

*Orfeo Toolbox*. O estudo conseguiu cobrir 8,9 km<sup>2</sup> e uma acurácia média de 98% na identificação de habitats do mosquito baseado em características de corpos d'água. O experimento ficou limitado apenas em corpos d'água sem realizar a abordagem de objetos como, vasos de plantas, pneus, caixas d'água, potes, baldes, que são potenciais criadouros de mosquitos, além disso as imagens inicialmente foram classificadas manualmente pelos autores.

Suduwella *et al.* (2017) propuseram um processo para identificação de criadouros de mosquitos em locais com água estagnada e inacessíveis a partir de imagens coletadas com drones no Sri Lanka. Os autores conseguiram uma acurácia acima de 81% no conjunto de dados DS2. No entanto, tal trabalho disponibiliza as imagens adquiridas.

Uma parcela considerável dos trabalhos levantados na revisão da literatura aborda o uso de drones para identificação automática de objetos e cenários suspeitos e de corpos d'água, conforme já detalhado anteriormente. No entanto, no que tange a identificação de pequenas porções de água, foram encontrados apenas os trabalhos de PRASAD (2015); BRAVO (2019) e BRAVO *et al.* (2019).

Prasad (2015) propôs um método baseado em combinação de método de cores e método baseado em fluxo óptico, e com isso identificar baixa saturação e alto brilho nas imagens e as aplicou em um classificador SVM para realizar a classificação das características da água, como por exemplo a propriedade de espelhamento. Entretanto, o método é propenso a falhas pois o fluxo óptico é incapaz de distinguir regiões distantes e pode identificar erroneamente objetos muito próximos que podem ser classificados como água, como exemplo, reflexos da luz solar em objetos como metais e vidros refletivos. Além disso, nos experimentos foram abordadas apenas poças d'água.

Já no trabalho de Bravo (2019), propôs um indicador baseado em Algoritmos Genéticos (AG), para identificação de água, utilizando as bandas RGB e NIR, mesmo com resultados promissores, o número de imagens empregada no experimento foi pequeno e não continham os principais objetos aos quais são potenciais criadouros de mosquitos, além do fato de que para obtenção da banda espectral infravermelho próximo, o autor empregou uma lente especial adaptada na câmera RGB, que provocou a contaminação das bandas do espectro visível.

Bravo *et al.* (2019) propuseram uma abordagem que combinam imagens aéreas do Espectro visível (VIS) e Infravermelho Próximo (NIR), adquiridas por

sensores utilizados em drones, e assim fornecer um índice indicativo para detecção de pequenas porções de água, utilizando técnicas de (AG) e Redes Neurais (RN). Os resultados alcançados na detecção de pequenas porções de água foram satisfatórios, no entanto, os autores utilizaram para os experimentos apenas imagens de piscinas e fontes, mas não empregaram objetos que são caracterizados como potenciais criadouros dos mosquitos, como caixas d'água, pneus, tambores, vasos de plantas e lixo inorgânico a céu aberto.

Explorando os estudos pode-se observar algumas lacunas, mas a principal delas é a não identificação de água nos cenários e objetos suspeitos, que limita muito a aplicação prática dos drones. Os poucos trabalhos, como os de Bravo *et al.* (2019); Bravo (2019) e Prasad (2015) que fazem menção às pequenas porções de água possuem limitações tanto nas imagens utilizadas, quanto nos métodos propostos. Assim, os SVCs propostos na literatura para identificação automática de potenciais focos de mosquitos ainda carecem de métodos computacionais para caracterização de água nos objetos e cenários detectados, para torná-los mais efetivos.

Neste contexto emerge a seguinte questão de pesquisa: como identificar água nos objetos e cenários que representam potenciais focos de mosquitos, a partir das imagens adquiridas por drones?

### 1.3 OBJETIVOS

#### 1.3.1 Objetivo Geral

Desenvolver método computacional empregando aprendizagem de máquina (AM) para identificação de pequenas porções de água em imagens multiespectrais adquiridas por drones.

#### 1.3.2 Objetivos Específicos

- Realizar de experimentos preliminares para definir qual algoritmo de AM é mais indicado para compor o método proposto;
- Desenvolver um método de aprendizagem de máquina para identificação de água;
- Compor uma base de imagens (incluindo imagens anotadas) para condução dos experimentos e avaliar o método proposto;

## 1.4 MOTIVAÇÃO E JUSTIFICATIVA

O uso de drones têm se mostrado uma tecnologia promissora para apoiar diversas áreas de estudos. Muitos pesquisadores vêm investindo na utilização de drones para identificação automática de criadouros de mosquitos, visto que eles facilitam as fiscalizações em áreas de difícil acesso, com menor tempo, menor custo e fornecem imagens com altas resoluções espacial e temporal, se comparadas com imagens de satélites.

Resolução espacial pode ser definida pela dimensão da área que cada pixel representa. Já a resolução espectral está relacionada à quantidade de bandas espectrais que os sensores levados a bordo de satélites podem medir, sendo que satélites possuem números bem superiores de sensores se comparados com câmeras acopladas em drones. Por fim, a resolução temporal pode ser definida como o período no qual um satélite torna a visitar uma determinada área no globo terrestre. O Landsat 8, por exemplo, demanda 16 dias para realizar esse processo (LABGEO, 2023).

Imagens coletadas a partir de sensores acoplados em drones se mostram mais adequadas para auxiliar a identificação de padrões relacionados aos focos de mosquitos visto que é possível obter imagens de alta resolução espacial, pois estão mais próximos ao solo, e melhor resolução temporal, podendo realizar imageamento em tempo real.

É importante destacar que a detecção de corpos d'água a partir de imagens de satélites é uma tarefa muito comum, sendo normalmente resolvida a partir do uso de características espectrais de imagens adquiridas por sensores específicos para compor assinaturas (ou índices) que caracterizam padrões atribuídos aos corpos d'água e a outros elementos da superfície terrestre (POLIDORIO et al., 2014).

No entanto, a detecção de água que possa estar contida em pequenos objetos a partir de imagens coletadas de sensores levados a bordo de satélite torna-se inviável devido às suas resoluções espaciais. Assim, se por um lado o uso de drones propicia a aquisição de imagens com altas resoluções espaciais e temporais, por outro lado normalmente os sensores acoplados a eles são de baixa resolução espectral, inviabilizando o uso das assinaturas espectrais propostas na literatura. É nesse contexto que se justifica o método proposto no presente trabalho.

Destaca-se que a investigação conduzida nesta pesquisa pode trazer contribuições para o cumprimento dos ODS estabelecidos pela Organização das Nações Unidas, especialmente o ODS 3 (Saúde e Bem-Estar), no que tange a redução da disseminação de enfermidades como malária, dengue e zika; o ODS 15 (Vida Terrestre), no que se refere a minimização de potenciais impactos ambientais adversos; e o ODS 9 (Indústria, Inovação e Infraestrutura), no que diz respeito a criação de soluções inovadoras para desafios de saúde pública e do meio ambiente.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são abordados tópicos que embasam o desenvolvimento teórico deste trabalho, como informações sobre o mosquito *Aedes aegypti* (seção 2.1), caracterização de corpos d'água em imagens digitais (seção 2.2) e aprendizagem de máquina (seção 2.3). Nesta última seção são apresentados conceitos sobre RNA e MLP, que são as bases do método proposto nesse trabalho.

### 2.1 MOSQUITO AEDES AEGYPTI: DOENÇAS TRANSMITIDAS, CICLO DE VIDA, HÁBITOS, LOCAIS DE PROLIFERAÇÃO E INSPEÇÃO DE POTENCIAIS CRIADOUROS NO BRASIL

*Aedes aegypti* é o nome do mosquito conhecido por ser o transmissor da dengue, da chikungunya, da zika e da febre amarela urbana (MS, 2022a; SESA, 2022). Sendo essas doenças chamadas de arboviroses, que são vírus transmitidos para hospedeiros. O mosquito é facilmente reconhecido devido sua característica diferenciada, que são listras brancas no tronco, em sua cabeça e pernas.

O *Aedes aegypti* é nativo da África, onde na década de 1950 foi erradicado no Brasil, entretanto, novos registros foram notificados na década de 1960 (FIOCRUZ MINAS, 2022). No que se refere às doenças, a dengue está presente atualmente em 130 países, a chikungunya em 115, o zika em 89 e a febre amarela em 40 (MS, 2022b). O Brasil está alinhado com a iniciativa Global de Arboviroses, quanto a vigilância e ações de assistência aos pacientes em fases aguda e crônica, assim como, abordagens de prevenção, controle, fortalecimento de serviços de saúde, diagnóstico, manejo clínico, capacidade de vigilância e controle de vetores (MS, 2022b).

O ciclo de vida do mosquito se divide em 4 fases, sendo elas: ovo, larva, pupa e adulta. Os locais que a fêmea costuma colocar seus ovos são úmidos e quentes, especificamente em recipientes como, vasos de plantas, pneus, tambores, calhas, piscinas, caixas d'água destampadas, lixo inorgânico a céu aberto ou qualquer outro objeto que possa acumular água parada (MS, 2022a; SESA, 2022; FIOCRUZ MINAS, 2022).

Os mosquitos machos e fêmeas possuem alimentações distintas, enquanto os machos se alimentam de seiva das plantas e as fêmeas necessitam de sangue para amadurecimento dos ovos, que não são colocados diretamente na água e sim nas

paredes dos recipientes e próximo a superfície da água. Esses locais oferecem melhores condições para a sobrevivência, havendo chuva e o nível da água do recipiente se elevando e entrando em contato com os ovos, basta 30 minutos para eles eclodirem e cerca de nove dias para os ovos chegarem na fase adulta (SESA, 2022).

O *Aedes aegypti* possui hábitos diurnos, vive em média 30 dias e a fêmea costuma viver dentro das casas em ambientes escuros e baixos com temperatura que variam entre 24 e 28°C, chega a colocar entre 150 e 200 ovos e não os colocam todos em um único recipiente, o que dificulta o trabalho de prevenção e controle larval (MS, 2022a; SESA, 2022; FIOCRUZ MINAS, 2022).

Existem regiões mais afetadas com a proliferação do mosquito, normalmente regiões com crescimento urbano desordenado, locais periféricos a qual a população possui menor renda, sendo locais com maior probabilidade de existência de objetos que são caracterizados potenciais criadouros do mosquito, como caixas d'água destampadas, pneus, garrafas e lixo inorgânico a céu aberto (FIOCRUZ MINAS, 2022; MS, 2022a, MS, 2022c).

Para controle e combate da proliferação do mosquito, o MS e cada município trabalham com conscientização da população através de campanhas, e com inspeções compostas por Agentes de Saúde através de ações de visitas domiciliares para identificação e contenção de focos larvais (MS, 2022a; MS, 2022c. Entretanto, fiscalizações com Agentes de Saúde são caras, demoradas, perigosas, limitadas e temporais, além de não garantirem a cobertura de grandes espaços urbanos, deixando uma lacuna em locais que necessitam de vistorias (GRUBESIC *et al.*, 2018).


## 2.2 CARACTERIZAÇÃO DE ÁGUA EM IMAGENS DIGITAIS

Corpo d'água pode ser descrito como qualquer acúmulo significativo de água na superfície terrestre ou em outro planeta, como mares, rios e lagos. Na literatura de sensoriamento remoto (SR) há muitos trabalhos abordando detecção de corpos d'água e outras assinaturas, como solo e vegetação, a partir de imagens de satélites. Existem índices que são calculados baseados nas bandas espectrais disponíveis nos satélites. Esses índices são amplamente utilizados no campo de SR para identificar água, sendo algum deles, NDWI – *Normalized Difference Water Index* (GAO, 1996) e

IIA – Índice Indicador de Água (POLIDORIO *et al.*, 2014), os quais são baseados na combinação das bandas verde visível (GREEN) e infravermelho próximo (NIR)

Como demonstrado na Figura 1, o IIA propicia indicações das características de reflectância de água por meio dos pixels com tons de cinza mais claros.

Figura 1: Identificação de corpos d'água a partir de imagens de satélite utilizando o IIA.




Fonte: Polidoro *et al.* (2014)

Segundo Polidoro *et al.* (2014), a água tem a característica de refletir uma parcela muito pequena da luminosidade incidida, pois a maior parte da energia luminosa incidente é transmitida, absorvida e dispersada pela água. O espectro da radiação refletida pela água ocupa, em geral, a faixa de comprimentos de onda entre 400 à 900nm, o que equivale à faixa do visível e o infravermelho-próximo.

A Figura 2 ilustra como são as medições de reflectância em comparação aos comprimentos de ondas, que são as bases para elaboração dos índices indicativos de corpos d'água, solo ou vegetação, criados a partir de imagens adquiridas por satélites. Pode-se verificar que as assinaturas espectrais de água limpa e turva, ficam entre as faixas do visível (VIS) e infravermelho-próximo (NIR). Vale lembrar que drones com câmeras multiespectrais podem adquirir imagens com alta resolução espacial e temporal, mas com quantidades de bandas espectrais inferiores se comparadas com as disponíveis em sensores acoplados aos satélites, o que pode inviabilizar o uso das assinaturas espectrais propostas na literatura para identificação de água nas imagens adquiridas por eles.

Figura 2: Assinaturas espectrais da água, solo e vegetação




Fonte: Florenzano (2014)

A MicaSense, empresa que desenvolveu a câmera *RedEdge-MX*, utilizada neste trabalho, fez a comparação do dispositivo com sensores de dois dos satélites mais utilizados em SR, o Sentinel 2A e Landsat 8. Essa comparação evidencia que os satélites possuem maior número de bandas espectrais, com faixas mais extensas, e consequentemente cobrem uma faixa maior dos espectros visível e não visível.

Na Figura 3 podem ser observadas essas diferenças entre as bandas espectrais e níveis de refletância dos sensores acoplados em satélites e de câmeras multiespectrais acopladas em drones.

Figura 3: Diferenças entre as bandas espectrais e níveis de refletância de sensores acoplados em satélites e a câmera RedEdge MX




Fonte: Micasense (2022)

## 2.3 APRENDIZAGEM DE MÁQUINA

Aprendizagem de Máquina (AM) é um ramo da inteligência artificial (IA), que por sua vez é subárea da ciência da computação. AM tem por objetivo o estudo e o desenvolvimento de métodos e técnicas que permitem aos sistemas computacionais aprenderem com dados, assim como reconhecer padrões para tomadas de decisões (GOODFELLOW, BENGIO e COURVILLE, 2016). Conforme define Mitchell (1997), “Diz-se que um programa de computador aprende pela experiência  $E$ , com respeito a algum tipo de tarefa  $T$  e performance  $P$ , se sua performance  $P$  nas tarefas em  $T$ , na forma medida por  $P$ , melhoram com a experiência  $E$ ”.

Quanto à forma de aprendizado, os algoritmos de AM podem ser divididos em supervisionado e não supervisionado, como ilustrado na Figura 4.

Figura 4: Hierarquia clássica de aprendizado



Fonte: FACELLI *et al.* (2021)

O aprendizado supervisionado pode ser definido como um paradigma de AM em que um modelo é treinado usando um conjunto de dados rotulados, ou seja, as entradas estão associadas a saídas conhecidas. Durante o treinamento, o modelo ajusta seus parâmetros para minimizar a diferença entre as saídas previstas e as saídas reais, aprendendo padrões e relações nos dados. O aprendizado não-supervisionado, por outro lado, envolve a modelagem de padrões em dados não rotulados, sendo que o modelo busca identificar estruturas, agrupamentos ou características ocultas sem orientação externa. Nesse caso, o próprio modelo extrai

informações significativas e organiza os dados com base em suas percepções, sem referência a respostas conhecidas (RUSSEL e NORVIG, 2004).

De acordo com Mitchell (1997), os algoritmos de AM podem ainda ser divididos de acordo com o tipo de tarefa que eles resolvem, conforme apresentado a seguir:

**Classificação:** é uma tarefa de aprendizado supervisionado em que o objetivo é atribuir uma ou mais categorias (rótulos) a um conjunto de dados com base em características ou atributos. O modelo de classificação aprende a relação entre os atributos e as categorias conhecidas durante o treinamento e, posteriormente, pode prever as categorias para novos dados.

**Regressão:** é outra tarefa de aprendizado supervisionado em que o objetivo é prever um valor numérico, geralmente contínuo, com base em uma ou mais variáveis independentes. O modelo de regressão aprende a relação entre as variáveis de entrada e a saída desejada durante o treinamento, permitindo a predição de valores para novos dados.

**Agrupamento:** o objetivo é dividir um conjunto de dados em grupos ou clusters com base em características semelhantes. Os pontos de dados dentro de um grupo são mais semelhantes entre si do que com os pontos em outros grupos. Os algoritmos de agrupamento identificam automaticamente padrões e estruturas nos dados, mas sem categorias pré-definidas.

**Associação:** visa descobrir padrões interessantes e relações entre itens em grandes conjuntos de dados. O objetivo é encontrar associações ou regras que indiquem a co-ocorrência de itens em transações ajudando, por exemplo, entender padrões de comportamento de consumidores.

**Sumarização:** é o processo de extrair informações essenciais e relevantes de um conjunto de dados extenso, resumindo-o de maneira concisa. Pode envolver a identificação de estatísticas importantes, tendências, padrões ou características chave para fornecer uma visão geral compreensível do conjunto de dados sem a necessidade de examinar todos os detalhes. Pode ser útil para simplificar a análise e a tomada de decisões.

Na literatura há inúmeras técnicas de AM para resolver as tarefas anteriormente descritas. Algumas das técnicas supervisionadas empregadas em classificação e regressão, e que foram consideradas nesta pesquisa para identificação de água em imagens multiespectrais, são brevemente apresentadas a seguir.

### 2.3.1 Redes Neurais Artificiais (RNA)


RNAs são baseadas em modelos matemáticos que se assemelham ao modelo biológico (cérebro humano). Segundo Haykin (2003), uma RNA se assemelha ao cérebro em dois aspectos: 1) a forma como aprende – o conhecimento é adquirido pela rede a partir de um processo de aprendizagem; 2) a forma como armazena o conhecimento – conexões entre neurônios, conhecidas como conexões sinápticas são utilizadas para armazenar o conhecimento adquirido.

As RNAs possuem capacidade além de mapear apenas relações de entradas e saídas, são capazes de aprender por meio de exemplos de generalização que faz com que esses modelos sejam grandes avanços para a tecnologia.

O processo de treinamento de uma RNA é executado a partir de um algoritmo de aprendizagem cuja principal função é fazer modificação dos pesos sinápticos para que as saídas sejam adequadas para a finalidade, que pode ser classificação ou regressão (DA SILVA & DE ASSIS BRITO FILHO, 2020).

Existem três classes de arquiteturas para RNAs, as quais são fundamentalmente distintas como ilustra a Figura 5:

Figura 5: Classes de arquiteturas de RNAs



Fonte: KAYKIN (2003)

- Camada única: forma mais simples de camadas que é composta por uma camada de entrada e uma camada de saída. Seu processo de aprendizado só é realizado para frente, ou seja, acíclica (Referência).

- Múltiplas camadas: possui uma ou mais camadas ocultas, neurônios ou unidades ocultas, cuja função é intervir entre as camadas de entrada e saída (KAYKIN, 2003). A rede adquire uma visão global apesar de sua atuação local, isso devido ao conjunto extra de conexões sinápticas e da dimensão a mais de interações neurais (CHURCHLAND e SEJNOWSKI, 1992).
- Redes recorrentes: diferem das RNAs de camada única e múltiplas camadas, pois é realizado um processo de realimentação através de pelo menos um laço de correção. A realimentação auxilia na capacidade de aprendizagem da rede e consequentemente no seu desempenho (KAYKIN, 2003).


#### 2.3.1.1 Redes Neurais Artificiais Multilayer Perceptron (RNA-MLP)

Redes neurais de múltiplas camadas, mais conhecidas como MLP (*Multilayer perceptron*) (RNA-MLP), são utilizadas para trabalhar com dados que não são linearmente separáveis. Esses modelos contemplam camadas de entradas e saídas, e também camadas ocultas (intermediárias). Com isso propiciam mapeamento de padrões de entradas similares, com saídas diferentes. O sinal de entrada é propagado para frente através da rede, camada por camada (HAYKIN, 2003).

Um dos algoritmos mais conhecidos quando se fala de MLP é o *backpropagation* (RUMELHART e MCCLELLAND, 1986), um algoritmo de aprendizado supervisionado que trabalha com correção de erros para ajuste de pesos, considerando os pares de entradas e saídas desejadas (BRAGA *et. al.*, 2000). Seu funcionamento consiste em duas etapas principais: propagação para frente e retropropagação. Na propagação para frente, os dados de entrada são passados pela rede neural, e as saídas são calculadas com base nos pesos das conexões. Na retropropagação, o erro entre as saídas previstas e os resultados desejados é calculado. Esse erro é então retropropagado pela rede, ajustando os pesos das conexões de forma a minimizar o erro através de técnicas de gradiente descendente, como o cálculo dos gradientes e a atualização iterativa dos pesos. Essa iteração entre propagação para frente e retropropagação ocorre durante o treinamento da rede, refinando os pesos e permitindo que a rede aprenda a melhor representação dos dados.

A Figura 6 ilustra uma arquitetura de MLP com duas camadas ocultas, sendo que todos os neurônios estão conectados da esquerda para a direita, camada por camada.

Figura 6: Exemplo de arquitetura MLP com camadas ocultas



Fonte: KAYKIN (2003)


Além de aprendizado supervisionado, existem também modelos de RNA baseados em aprendizado não-supervisionado, que são principalmente utilizados para problemas de agrupamento de dados e mapeamento de características (JAIN et. al., 2000, 1996).

### 2.3.2 Support Vector Machines (SVM)

*Support Vector Machine* (SMV) é um método de aprendizagem supervisionado utilizado para problemas de classificação e regressão. A técnica foi introduzida por Cortez e Vapnik (1995), os quais descrevem que SVM conceitualmente são vetores de entrada mapeados não linearmente, para um espaço de características de dimensão muito alta. Nesse espaço de características uma superfície de decisão linear é construída. Com isso, propriedades especiais da superfície de decisão garantem alta capacidade de generalização. SVM também utiliza a transformação de entradas polinomiais. Em resumo, SVM combina três ideias: a) técnica de hiperplanos ótimos que permite uma expansão de vetor de solução em vetores de suporte; b) convolução do produto escalar que estende as superfícies da solução linear para não linear; c) noção de margens suaves para permitir erros no conjunto de treinamento (CORTES e VAPNIK, 1995).

Nas ilustrações das Figuras 7a e 7b são demonstradas classificações de dados que podem ser separados linearmente em duas classes utilizando SVM, com um e com três hiperplanos.

Figura 7: Exemplos de classificação linear utilizando SVM




a) Duas classes e um hiperplano

b) Duas classes e três hiperplanos

Na Figura 8a é possível verificar que o método busca determinar o parâmetro de uma linha, maximizando a distância (margem) do vetor de suporte, com isso identifica classes que estão mais próximas dessa fronteira. Na Figura 8b, temos mais de um hiperplano, logo o vetor de suporte tentará encontrar um ou mais hiperplanos que mais se aproximam das classes. Nesse cenário, os hiperplanos A e C foram os que maximizaram os resultados para a classe 1 e para a classe 2.

SVM também trata a classificação de dados que não podem ser separados linearmente (Figura 8a) ou que precisam ser transformados para um novo espaço de maior dimensão, denominado espaço de características como pode ser verificado na Figura 8b.

Figura 8: Exemplos de classificação não linear utilizando SVM




### 2.3.3 Nearest Neighbors Classification (K-NN)

O algoritmo *Nearest Neighbors Classification* (K-NN) é um método de aprendizagem de máquina supervisionado desenvolvido por Evelyn e Joseph (1951) e evoluído por Thomas e Peter (1967), e que pode ser utilizado tanto para classificação quanto para regressão.

Na classificação, o algoritmo determina a classe de uma nova instância com base na maioria das classes das K instâncias de treinamento mais próximas à essa instância, sendo K um hiperparâmetro. A distância entre as instâncias é geralmente medida usando métricas, como a conhecida distância euclidiana. No caso da regressão, o K-NN calcula a média (ou mediana) dos valores alvo dos K vizinhos mais próximos para prever o valor da nova instância. Trata-se de um algoritmo simples e intuitivo, mas que pode ser computacionalmente custoso, especialmente para grandes conjuntos de dados. Além disso, a escolha adequada de K também podem impactar a performance e a generalização do algoritmo (FACELLI *et al.*, 2021).

Na Figura 9 é ilustrado o funcionamento de algoritmo KNN para diferentes valores de K, considerando classes de pessoas saudáveis e doentes.

Figura 9: Exemplo de classificação com algoritmo K-NN



Fonte: FACELLI *et al.* (2021)

O algoritmo K-NN é baseado em memória, ou seja, é considerado um algoritmo preguiçoso, porque toda a computação é adiada até a fase de classificação, sendo que o processo de aprendizado está relacionado na memorização das instâncias ou objetos (FACELLI *et al.*, 2021).

#### 2.3.4 Random Forest (RF)

Florestas aleatórias (*Random Forest* - RF) é um método de aprendizagem de máquina que combina a predição de múltiplas árvores de decisão (AD), formando uma "floresta". Cada AD é treinada em uma amostra aleatória dos dados de treinamento e utilizando um subconjunto aleatório de características (atributos). Durante a predição, cada AD na floresta emite uma resposta, e a classe ou a média das respostas é considerada como a predição final do algoritmo. Isso ajuda a reduzir o *overfitting* e a melhorar a generalização do modelo. Em adição, o RF pode lidar com conjuntos de dados grandes, variáveis categóricas e numéricas, sendo eficaz tanto para tarefas de classificação quanto de regressão. É uma escolha popular para sua robustez, flexibilidade e capacidade de lidar com alta dimensionalidade e dados ruidosos (HASTIE, 2008).

No geral, o RF é uma escolha popular em muitos cenários de aprendizado de máquina em virtude da sua robustez, capacidade de lidar com diferentes tipos de dados e eficácia na obtenção de resultados precisos e confiáveis.

### 3 MATERIAL E MÉTODO

Neste capítulo são apresentados os materiais e os métodos empregados na pesquisa. Primeiro é apresentada a base de imagens na seção 3.1. Na seção 3.2 são apresentados experimentos preliminares para definição do algoritmo de AM. Na sequência, o método proposto é descrito na seção 3.3. Por fim, na seção 3.4, são descritos os procedimentos para condução dos experimentos e avaliação dos resultados.


#### 3.1 BASE DE IMAGENS

A base de imagens utilizada nos experimentos descritos neste trabalho foi composta conforme detalhamento a seguir:


- A aquisição das imagens foi realizada no Laboratório de Geotecnologias (LABGEO) da Universidade Presbiteriana Mackenzie em São Paulo, nos dias 07 de junho de 2022 e 02 de maio de 2023.
- Foram compostos dois conjuntos de imagens utilizando objetos com diferentes capacidades de armazenamento e que poderiam ou não conter água, que por sua vez, poderia estar limpa ou suja.
- Nas aquisições das imagens foi utilizada a câmera *RedEdge-MX<sup>1</sup>* da Micasense, que normalmente é acoplada a drones e que captura e armazena as bandas espectrais de cada imagem separadamente. Cada imagem adquirida possui 5 bandas espectrais: (a) *blue*; (b) *green*; (c) *red*; (d) *Infra-red* (d); (e) *RedEdge*.
- As imagens foram adquiridas posicionando a câmera do drone a uma distância de aproximadamente 2 m acima dos objetos que compuseram cenários simulados. Em outras palavras, para gerar cada cenário simulado, um conjunto de recipientes (vazios / contendo água) era colocado no chão, e então uma ou mais fotos (imagens) eram adquiridas do cenário.
- Para composição de cada conjunto foram considerados diferentes cenários empregando cinco recipientes (objetos – OBJ), com as capacidades ilustradas na Figura 10, os quais poderiam estar nos seguintes estados:

Cheio (C); Meio cheio (M); Vazio (V), e contendo água suja (\*). Os cenários considerados nesta pesquisa são apresentados nas tabelas 1 e 2.

Figura 10: Distribuição dos objetos e suas capacidades de armazenamento em litros. (a) conjunto 1; (b) conjunto 2



(a) Imagem do cenário 3 do  
Conjunto 1



(b) Imagem do cenário 2 do  
Conjunto 2

Tabela 1: Cenários do Conjunto 1

| CENARIO | OBJ1 | OBJ2 | OBJ3 | OBJ4 | OBJ5 |
|---------|------|------|------|------|------|
| 1       | C    | C    | C    | C    | C    |
| 2       | C    | C    | M    | M    | M    |
| 3       | C    | C    | V    | V    | V    |
| 6       | C    | M    | M    | M    | M    |
| 5       | C    | V    | V    | V    | V    |
| 4       | M    | M    | M    | M    | M    |
| 7       | M    | M    | C    | C    | C    |
| 8       | M    | M    | V    | V    | V    |
| 9       | M    | C    | C    | C    | C    |
| 10      | M    | V    | V    | V    | V    |
| 11      | V    | V    | V    | V    | V    |
| 12      | V    | V    | M    | M    | M    |
| 13**    | V    | V    | C    | C    | C    |
| 14      | V    | M    | M    | M    | M    |
| 15      | V    | C    | C    | C    | C    |
| 16      | C*   | C*   | C*   | C*   | C*   |
| 17      | M*   | M*   | M*   | M*   | M*   |

(\*) Água suja; (\*\*) Imagem da Figura 11


Tabela 2: Cenários do Conjunto 2

| CENÁRIO    | OBJ1     | OBJ2     | OBJ3     | OBJ4     | OBJ5     |
|------------|----------|----------|----------|----------|----------|
| <b>1</b>   | C        | C        | C        | C        | C        |
| <b>2**</b> | <b>C</b> | <b>C</b> | <b>C</b> | <b>C</b> | <b>V</b> |
| <b>3</b>   | C        | C        | C        | V        | V        |
| <b>4</b>   | C        | C        | V        | V        | V        |
| <b>5</b>   | C        | V        | V        | V        | V        |
| <b>6</b>   | V        | V        | V        | V        | V        |
| <b>7</b>   | V        | V        | V        | V        | C        |
| <b>8</b>   | V        | V        | V        | C        | C        |
| <b>9</b>   | V        | V        | C        | C        | C        |
| <b>10</b>  | V        | C        | C        | C        | C        |

(\*\*) Imagem da Figura 11

Foram coletadas 151 imagens, sendo 56 no dia 07/06/22 (Conjunto 1) e 95 no dia 02/05/23 (Conjunto 2). Dessas imagens, 37 (~25%) foram usadas na avaliação do método proposto (24 do Conjunto 1, e 13 do Conjunto 2). Um exemplo de imagem do Conjunto 1 é ilustrado na Figura 11.

Figura 11: Bandas espectrais de uma imagem do Conjunto 1 – Cenário 3. (a) blue; (b) green; (c) red; (d) Infra-red (d); (e) RedEdge;



### 3.2 EXPERIMENTOS PRELIMINARES PARA DEFINIÇÃO DO ALGORITMO DE AM EMPREGADO NO MÉTODO PROPOSTO

A escolha da RNA MLP para compor o método proposto foi feita com base em experimentos preliminares, nos quais foram comparados os seguintes algoritmos: MLP (*Multilayer Perceptron*), SVM (*Support Vector Machines*), KNN (*Nearest Neighbors Classification*) e RDF (*Random Forests*). Em tais experimentos foram comparados tanto modelos classificação quanto de regressão, como ilustrado na Figura 12 e detalhado na Tabela 3. Em adição, foram consideradas 2 classes – 2CL (Água e Não Água) e 3 classes – 3CL (C, M, V) nos experimentos.

Figura 12: Comparação dos modelos de classificação e de regressão nos experimentos preliminares





Tabela 3: Acurácias dos algoritmos de regressão e de classificação nos experimentos preliminares

| Algoritmo | Classificação | Classificação | Regressão | Regressão |
|-----------|---------------|---------------|-----------|-----------|
|           | 2CL           | 3CL           | 2CL       | 3CL       |
| MLP       | 80,10         | 48,69         | 83,15     | 70,44     |
| SVM       | 79,37         | 33,88         | 82,30     | 69,65     |
| KNN       | 76,14         | 33,21         | 74,85     | 70,67     |
| RDF       | 77,80         | 33,58         | 75,20     | 55,70     |

Como pode ser visto na Tabela 3 e na Figura 12, os melhores resultados foram obtidos pelo modelo de regressão usando MLP, levando em conta apenas duas classes.


Os experimentos foram conduzidos levando em conta o uso do PCA (*Principal Component Analysis*) e normalização de dados (método PCA.fit), que permitiu reduzir o número de atributos sem comprometer a qualidade dos dados. Isso foi feito em virtude da constatação de que algumas bandas estavam muito correlacionadas, como pode ser visto na Figura 13, o que poderia prejudicar o treinamento da RNA.

Figura 13: Correlações entre as bandas espectrais das imagens



Uma visualização dos dados no espaço PCA, que produziu 3 atributos representativos a partir das 5 bandas espectrais, é apresentada na Figura 14.

Figura 14: Visualização dos dados no espaço PCA (com 3 atributos)




Após treinamentos realizados verificou-se que essa transformação dos dados (PCA + normalização) foi uma boa alternativa para diminuir a correlação entre as bandas, proporcionando uma melhora significativa nos resultados.

### 3.3 MÉTODO DE AM PROPOSTO

Nesta seção é detalhado o método proposto, cujo diagrama de funcionamento é ilustrado na Figura 15.

Figura 15: Diagrama do funcionamento do método proposto



Na seção 3.3.1 são descritas as etapas de delimitação das regiões de interesse (*Region of Interest* – ROI) e anotações das imagens. Na sequência, é descrito o


processo de extração das características, transformação de dados usando PCA e a composição dos conjuntos de treinamento e de teste (seção 3.3.2). Na seção 3.3.3 descreve-se como foram realizados o treinamento e os testes da RNA. Por fim, na seção 3.3.4 é descrito o processo para classificar os pixels de uma imagem multiespectral utilizando a RNA treinada (predições).

### 3.3.1 Segmentação e anotação das imagens

Neste trabalho buscou-se automatizar o processo de segmentação das regiões de interesse (*region of interest* – ROI), entretanto, ainda foi necessário interferir em alguns procedimentos para obtenção do melhor resultado no menor tempo. Sendo assim, pode-se considerar que esse processo é semi-automatizado.


O primeiro procedimento foi o “ajuste” das imagens para posterior extração da ROI, pois a câmera multiespectral utilizada no experimento obtém as imagens em posições espaciais distintas devido a posição dos sensores na câmera. Com isso, ao combinar as bandas das imagens originais elas ficam deslocadas após a sobreposição, como ilustrado na Figura 16, o que inviabilizaria a extração de características tendo em vista que um pixel ocupa posição diferente dependendo da banda espectral. Em outras palavras, o pixel (0,0) na banda R, por exemplo, não está localizado nesta mesma posição nas demais bandas. Além disso, foram necessários ainda ajustes de rotação para alinhamento das imagens.

Figura 16: Posição e identificação espacial dos sensores da câmera RedEdge MX




Outro ponto é que existem partes na imagem que podem ser desconsideradas. Assim, convencionou-se que seria utilizada apenas uma região retangular centralizada na imagem, como ilustrado na Figura 17. Esse procedimento de recorte da “área útil” melhora os passos de processamento seguintes, já que há uma redução das dimensões da imagem, passando de 1280×960 para 730×540.

Figura 17: Ajustes das imagens para adequada seleção da ROI



(a) Sobreposição das bandas sem adequado ajuste de rotação



(b) Seleção da região apropriada para ajuste de rotação e dimensionamento

Após realizados os ajustes mencionados e o recorte das imagens originais, nas quais os pixels mantêm as posições independente da banda, pode-se obter imagens com as bandas combinadas, como mostrado na Figura 18.


Figura 18: Imagem combinando as bandas RGB após ajustes e recorte



O próximo passo foi delimitação das ROI. Para tanto, desenvolveu-se um procedimento para identificação das bordas de cada objeto contido na imagem. Como todos os objetos empregados na aquisição das imagens eram circulares, foram computados o raio e as coordenadas de centro ( $x_c$ ,  $y_c$ ) de cada objeto, que são armazenados em um arquivo texto com o mesmo nome da imagem processada. Na sequência, a informação relativa à cor para rotulação (anotação) de cada objeto, de acordo com a classe ("C": Azul, "M": Verde e "V: Vermelho), foi incluída manualmente no arquivo texto.

No último passo, usando as informações armazenadas no arquivo texto de anotação, os objetos de cada imagem são automaticamente rotulados (“coloridos”). Deste modo, obtém-se as imagens anotadas, como ilustrado na Figura 19, as quais norteiam a extração dos valores das bandas dos pixels pertencentes às ROIs das imagens originais, para composição dos conjuntos de treinamento e de teste.

Figura 19: Exemplo de imagem anotada indicando as ROIs



### 3.3.2 Extração de características, transformação de dados e composição dos conjuntos de treinamento e teste da RNA

Nesta etapa do método são realizados os passos de processamento ilustrados na Figura 20, e descritos nos passos (a) até (d) a seguir.

(a) Realiza-se a extração dos atributos (características) das imagens originais com base nas ROIs definidas nas imagens anotadas. Neste trabalho os atributos consistem nos níveis de cinza das bandas espectrais (R, G, B, NIR e *RedEdge*) dos pixels pertencentes aos objetos. Com isso, um conjunto inicial de dados é composto. Vale ressaltar que as imagens anotadas servem para definir em quais regiões serão selecionados os atributos para compor a base de treinamento e de teste.

(b) Na etapa seguinte é feita a transformação do conjunto de dados utilizando o PCA (*Principal Component Analysis*), com o objetivo de manter apenas as 3 características mais importantes para classificação. Para aplicação do PCA empregou-se a rotina `sklearn.decomposition.PCA`<sup>1</sup> da biblioteca *Scikit-learn*, uma API

---


<sup>1</sup> <https://scikit-learn.org/stable/modules/generated/sklearn.decomposition.PCA.html>

(*application programming interface*) de aprendizagem de máquina de código aberto para a linguagem *Python*

(c) A transformação de dados inclui ainda a normalização dos valores do conjunto de dados no espaço PCA para o intervalo  $[0, 1]$  (escalonamento). Para tanto, foi utilizada a rotina *StandardScaler*<sup>2</sup> da biblioteca *Scikit-learn*. A normalização de dados é crucial para evitar que atributos dominantes prejudiquem o desempenho de algoritmos de aprendizado de máquina.

(d) Após aplicar a transformação (PCA + Normalização) no conjunto de dados gerado no passo (a) tem-se um conjunto de dados transformado, o qual dá origem aos conjuntos de treinamento e teste.

Figura 20: Esquema completo para montagem do arquivo de treinamento e teste



<sup>2</sup> [https://scikit-](https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html#sklearn.preprocessing.StandardScaler)

[learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html#sklearn.preprocessing.StandardScaler](https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html#sklearn.preprocessing.StandardScaler)

### 3.3.3 Treinamento e teste da RNA

A RNA que compõe o método é um modelo de regressão que recebe como entrada um vetor com os valores das bandas espectrais de um pixel da imagem (*blue*, *green*, *red*, *Infra-red* e *RedEdge*), submete-o ao processo de transformação de dados (PCA+Normalização), e prediz se o pixel pertence a uma região de água ou não água.

Em resumo, a RNA é treinada com as características extraídas das imagens que compuseram os conjuntos de treinamento e teste.

Para desenvolvimento da RNA foi utilizada a biblioteca do *Scikit-learn*<sup>3</sup>. No treinamento foi utilizado o método de *Grid Search*, o qual faz uma busca exaustiva visando otimizar os hiperparâmetros de configuração do algoritmo ('*solver*', '*activation*', '*max\_iter*', '*max\_func*' e '*hidden\_layer\_sizes*'). Informações detalhadas sobre cada um desses parâmetro estão disponíveis na documentação do método *GridSearchCV*<sup>4</sup>.

Os experimentos foram realizados considerando a divisão das imagens separadas para treinamento e teste com proporções de 75 e 25%. Para treinamento da RNA foram realizadas algumas operações para melhorar o resultado do modelo final, como balanceamento do conjunto de dados, para uma melhor distribuição das classes, evitando dar mais peso para a classe “não água” que contempla muito mais exemplos de treinamento. Em adição, o método de validação cruzada foi empregado no treinamento.

Para definição da classe a partir da saída RNA, que é um valor contínuo no intervalo [0, 1], adotou-se o limiar de 0,3, baseado em experimentos preliminares, que estão mais detalhados na seção 4.1. A determinação da classe do pixel conforme o valor de saída (*y*) da RNA é feita de acordo com a equação 1.

$$\begin{cases} 1, & \text{se } y \geq \text{limiar} \\ 0, & \text{caso contrário} \end{cases} \quad (1)$$

O total de exemplos processados no conjunto de teste foi 223.678, distribuídos igualmente entre as classes “0” – Não água e “1” – Água. Desses, 80.103 dos 111.839 da classe água foram classificados corretamente, o que reflete uma sensibilidade de 71,62%.

<sup>3</sup> <https://scikit-learn.org/stable/>


<sup>4</sup> [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.GridSearchCV.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html)

### 3.3.4 Classificação dos pixels de uma imagem usando a RNA treinada

A classificação dos pixels de uma imagem com base nas previsões da RNA (ilustrado na Figura 21) é feita de acordo com os seguintes passos:

- Cada imagem é processada pixel a pixel. Para cada pixel são extraídos os valores das bandas R, G, B, NIR e *RedEdge*, compondo um conjunto de dados
- Na sequência é realizada a transformação do conjunto de dados. Isso resulta em um vetor de 3 elementos a partir do qual é feita a predição;
- O valor da predição da RNA é então limiarizado permitindo classificar o pixel como “0” (Não Água) ou “1” (Água), na imagem de saída. Isso permite rotular cada um dos pixels com cor Vermelha – Não água) ou Azul – água. Por fim, é obtida uma imagem de saída, que pode ser comparada com a imagem anotada (no caso das imagens separadas para treinamento e validação).

Figura 21: Classificação dos pixels de uma imagem pela RNA-MLP



## 3.4 PROCEDIMENTOS PARA CONDUÇÃO DOS EXPERIMENTOS E AVALIAÇÃO DO MÉTODO PROPOSTO

Para avaliação do método proposto foram empregadas 37 imagens, sendo 24 do Conjunto 1 e 13 do Conjunto 2. Cada imagem foi submetida à RNA treinada gerando uma imagem de saída com os pixels classificados. Assim, foi possível computar as métricas que indicam o desempenho do método para cada imagem, e para o cada Conjunto de imagens.

Foram computadas as seguintes medidas de desempenho: precisão, sensibilidade e acurácia, levando em conta os acertos e erros definidos por:

- Verdadeiro Positivo (VP): refere-se à predição realizada corretamente como água.
- Falso Positivo (FP): detecção de água em regiões da imagem que não possuem água.
- Verdadeiro Negativo (VN): classificação correta dos pixels que não representam água.
- Falso Negativo (FN): predição realizada incorretamente como não água.

A precisão (Equação 2) indica a proporção de VP em relação ao total de pixels classificados como água.

$$precisão = \frac{VP}{VP + FP} \quad (2)$$

A sensibilidade (Equação 3) indica a proporção de VP em relação ao número de pixels que verdadeiramente representam água.

$$Sensibilidade = \frac{VP}{VP + FN} \quad (3)$$

A acurácia (Equação 4) indica a proporção de pixels corretamente classificados como água ou não água.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (4)$$

A precisão e a sensibilidade são importantes para indicar pixels que foram classificados corretamente como água (VP), e, portanto, são as principais medidas para avaliar o método proposto. A diferença entre elas é que a primeira leva em conta os falsos positivos (pixels classificados incorretamente como água). Já a acurácia leva em consideração todas as classificações (VP, VN, FP e FN).

Apesar da acurácia ser uma medida amplamente utilizada na literatura, ela não é a mais adequada para os experimentos descritos nesta pesquisa tendo em vista que, em geral, numa imagem a ser classificada há muito mais pixels da classe não-

água, levando a um desbalanceamento entre VP e VN. Em outras palavras, dependendo da imagem, se todos os pixels forem classificados como não-água, ainda assim a acurácia será alta.

A RNA foi treinada e avaliada levando-se em conta características extraídas dos conjuntos de imagens isolados e combinados.

## 4 RESULTADOS E DISCUSSÃO

Na subseção 4.1 são descritos os resultados com a RNA com a MLP treinada para a partir de características extraídas dos conjuntos 1 e 2 isoladamente, enquanto a subseção 4.2 apresenta os resultados considerando um único conjunto de treinamento extraído dos conjuntos 1 e 2. Por fim, na subseção 4.3 apresenta-se uma breve discussão dos resultados

### 4.1 RESULTADOS OBTIDOS COM A RNA-MLP TREINADA COM OS DADOS DOS CONJUNTOS 1 E 2 ISOLADOS

Considerando a RNA-MLP treinada com o Conjunto 1 foi obtida precisão média de 0,759 e sensibilidade média de 0,9436. Os resultados para cada imagem são apresentados na Tabela 4. Já as figuras 22c e 22f ilustram exemplos de classificações dos pixels de duas imagens do Conjunto 1 (cenários 1 e 16).

Tabela 4: Resultados obtidos pela RNA MLP treinada com o Conjunto 1


| <b>Imagem de teste</b> | <b>Precisão</b> | <b>Sensibilidade</b> |
|------------------------|-----------------|----------------------|
| MICA_CEN01_V1          | 1,00            | 0,93                 |
| MICA_CEN01_V2          | 1,00            | 0,94                 |
| MICA_CEN01_V3          | 1,00            | 0,92                 |
| MICA_CEN03_V1          | 0,58            | 1,00                 |
| MICA_CEN03_V2          | 0,56            | 1,00                 |
| MICA_CEN03_V3          | 0,57            | 1,00                 |
| MICA_CEN11_V1          | *               | *                    |
| MICA_CEN13_V1          | 0,46            | 0,89                 |
| MICA_CEN13_V2          | 0,45            | 0,90                 |
| MICA_CEN13_V3          | 0,45            | 0,87                 |
| MICA_CEN14_V1          | 0,67            | 0,95                 |
| MICA_CEN14_V2          | 0,66            | 0,96                 |
| MICA_CEN14_V3          | 0,65            | 0,96                 |
| MICA_CEN15_V1          | 0,66            | 0,92                 |
| MICA_CEN15_V2          | 0,67            | 0,95                 |
| MICA_CEN15_V3          | 0,66            | 0,93                 |
| MICA_CEN15_V4          | 0,66            | 0,92                 |
| MICA_CEN16_V1          | 1,00            | 0,96                 |
| MICA_CEN16_V2          | 1,00            | 0,94                 |
| MICA_CEN16_V3          | 1,00            | 0,95                 |
| MICA_CEN16_V4          | 1,00            | 0,96                 |
| MICA_CEN16_V5          | 1,00            | 0,95                 |
| MICA_CEN16_V6          | 1,00            | 0,96                 |
| <b>Média</b>           | <b>0,759</b>    | <b>0,9436</b>        |

\* Imagens que não contém água nos recipientes do cenário.


Figura 22: Exemplos de resultados da RNA treinada com o (Conjunto 1)

Cenário 01 – Todos os recipientes contendo água


Cenário 16 – Todos os recipientes com água pela metade




(a) MICA\_CEN01\_V1 - Original – bandas R, G, B, NIR, EDG




(d) MICA\_CEN16\_V4 - Original – bandas R, G, B, NIR, EDG




(b) MICA\_CEN01\_V1\_ANOTADA



(e) MICA\_CEN16\_V4\_ANOTADA



(c) MICA\_CEN01\_V1 - Classificada  
(precisão = 1,00)



(f) MICA\_CEN16\_V4 - Classificada  
(precisão = 1,00)

A precisão para ambas as imagens foi 1,00, uma vez que elas contêm apenas recipientes com água. Já a sensibilidade foi 0,93 em virtude da incidência de casos FN.

Na matriz de confusão apresentada na Tabela 5 é possível verificar o detalhamento das classificações dos pixels da imagem MICA\_CEN01\_V1.

Tabela 5: Matriz de confusão – imagem MICA\_CEN01\_V1

|             |                 | Classe predita |          |                 |
|-------------|-----------------|----------------|----------|-----------------|
|             |                 | Água           | Não água | Total de pixels |
| Classe real | Água            | 79659          | 0        | 79659           |
|             | Não água        | 5794           | 85453    | 91247           |
|             | Total de pixels | 85453          | 85453    | 170906          |

- Precisão:  $79659 / (79659 + 0) = 1$  (100%)
- Sensibilidade:  $79659 / (79659 + 5794) = 0,93$  (93%)

Com relação aos resultados da RNA-MLP treinada com o conjunto 2, foi obtida precisão média de 0,5543 e sensibilidade média de 0,9855 como apresentado na Tabela 6. As figuras 23c e 23f ilustram exemplos de classificações dos pixels de duas imagens do Conjunto 2 (cenários 1 e 10)


Tabela 6: Resultados obtidos pela RNA MLP treinada com o Conjunto 2

| Imagem de teste | Precisão      | Sensibilidade |
|-----------------|---------------|---------------|
| MICA_CEN01_V1   | 1,00          | 0,97          |
| MICA_CEN01_V2   | 1,00          | 1,00          |
| MICA_CEN07_V5   | 0,40          | 0,99          |
| MICA_CEN07_V6   | 0,40          | 0,99          |
| MICA_CEN07_V7   | 0,40          | 0,99          |
| MICA_CEN07_V8   | 0,40          | 0,99          |
| MICA_CEN07_V9   | 0,40          | 0,99          |
| MICA_CEN10_V1   | 0,92          | 1,00          |
| MICA_CEN10_V2   | 0,94          | 0,96          |
| MICA_CEN10_V3   | 0,94          | 0,98          |
| MICA_CEN10_V4   | 0,96          | 0,98          |
| MICA_CEN12_V1   | *             | *             |
| MICA_CEN12_V2   | *             | *             |
| MICA_CEN12_V3   | *             | *             |
| <b>Média</b>    | <b>0,5543</b> | <b>0,9855</b> |


\* Imagens que não contém água nos recipientes do cenário.

Figura 23: Exemplos de resultados da RNA treinada com o (Conjunto 2)


Cenário 01 – Todos os recipientes contendo água



(a) MICA\_CEN01\_V1 - Original – bandas R, G, B, NIR, EDG




(b) MICA\_CEN01\_V1\_ANOTADA




(c) MICA\_CEN01\_V1 - Classificada  
(precisão = 1,00)


Cenário 10 – recipiente OBJ1 vazio e demais contendo água



(d) MICA\_CEN10\_V3 - Original – bandas R, G, B, NIR, EDG



(e) MICA\_CEN10\_V3\_ANOTADA



(f) MICA\_CEN10\_V4 - Classificada  
(precisão = 0,96)

A precisão para ambas as imagens foi 1,00, uma vez que as imagens contêm apenas recipientes com água. Já a sensibilidade foi 0,96 em virtude da incidência de casos FN.

Na matriz de confusão apresentada na Tabela 7 é possível verificar o detalhamento das classificações dos pixels da imagem MICA\_CEN01\_V1 (do Conjunto 2).

Tabela 7: Matriz de confusão — imagem MICA\_CEN01\_V1

|             |                 | Classe predita |          |                 |
|-------------|-----------------|----------------|----------|-----------------|
|             |                 | Água           | Não água | Total de pixels |
| Classe real | Água            | 24411          | 0        | 24411           |
|             | Não água        | 690            | 25101    | 25791           |
|             | Total de pixels | 25101          | 25101    | 50202           |

- Precisão:  $24411 / (24411 + 0) = 1$  (100%)
- Sensibilidade:  $24411 / (24411 + 690) = 0,97$  (97%)

Treinar duas RNAs, uma com dados oriundos do Conjunto 1 e outra com dados do Conjunto 2, foi importante para possibilitar a investigação das condições de iluminação assim como as posições dos recipientes utilizados nas aquisições das imagens. Outro fator é que os tipos de objetos, tamanhos e quantidade de água contida neles foram bem diferentes, como detalhado na seção 3.1.

Com base nos resultados apresentados nas tabelas 4 e 6 pode-se verificar que o Conjunto 1 obteve melhores resultados, se comparado com os resultados obtidos para o Conjunto 2.

A diferença entre os resultados obtidos para os conjuntos avaliados individualmente pode estar relacionada com as posições, tamanhos, e distribuição dos objetos nos experimentos realizados. Na aquisição das imagens do Conjunto 2, os recipientes eram bem menores se comparados com os objetos do Conjunto 1. Assim, o número de pixels é menor levando a uma menor quantidade de informações no processo de aprendizagem da RNA—MLP.

Para ambos os conjuntos as RNAs apresentam boas precisões e sensibilidades, principalmente nos cenários nos quais a maior parte ou todos os recipientes contém água, o que demonstra que elas são muito úteis para indicar pixels de regiões contendo água. Vale ressaltar nos cenários que existiam distribuição equilibrada de recipientes com água e vazios (não água), a precisão diminui.

## 4.2 RESULTADOS OBTIDOS COM A RNA-MLP TREINADA COM OS DADOS DOS CONJUNTOS 1 E 2 UNIFICADOS

Considerando a RNA-MLP treinada com um único conjunto de dados extraídos dos conjuntos 1 e 2, foi obtida precisão média de 0,7421 e sensibilidade média de 0,7638. Os resultados para cada imagem de teste são apresentados na Tabela 8. Já as figuras 24c e 24f ilustram exemplos de classificações dos pixels de duas imagens do Conjunto 1 (cenários 1) e Conjunto 2 (cenário 1).

Tabela 8: Resultados obtidos pela RNA MLP dos conjuntos 1 e 2 unificados


| Conjunto           | Imagem de teste | Precisão      | Sensibilidade | Acurácia      |
|--------------------|-----------------|---------------|---------------|---------------|
| 1                  | MICA_CEN01_V1   | 1,00          | 0,76          | 0,76          |
| 1                  | MICA_CEN01_V2   | 1,00          | 0,78          | 0,78          |
| 1                  | MICA_CEN01_V3   | 1,00          | 0,66          | 0,66          |
| 1                  | MICA_CEN03_V1   | 0,77          | 0,81          | 0,76          |
| 1                  | MICA_CEN03_V2   | 0,52          | 0,80          | 0,50          |
| 1                  | MICA_CEN03_V3   | 0,57          | 0,81          | 0,57          |
| 1                  | MICA_CEN11_V1   | *             | *             | 0,49          |
| 1                  | MICA_CEN13_V1   | 0,53          | 0,88          | 0,56          |
| 1                  | MICA_CEN13_V2   | 0,50          | 0,83          | 0,52          |
| 1                  | MICA_CEN13_V3   | 0,53          | 0,90          | 0,57          |
| 1                  | MICA_CEN14_V1   | 0,64          | 0,74          | 0,54          |
| 1                  | MICA_CEN14_V2   | 0,35          | 0,41          | 0,38          |
| 1                  | MICA_CEN14_V3   | 0,62          | 0,78          | 0,54          |
| 1                  | MICA_CEN15_V1   | 0,63          | 0,74          | 0,53          |
| 1                  | MICA_CEN15_V2   | 0,46          | 0,38          | 0,28          |
| 1                  | MICA_CEN15_V3   | 0,61          | 0,68          | 0,49          |
| 1                  | MICA_CEN15_V4   | 0,58          | 0,59          | 0,43          |
| 1                  | MICA_CEN16_V1   | 1,00          | 0,93          | 0,93          |
| 1                  | MICA_CEN16_V2   | 1,00          | 0,87          | 0,87          |
| 1                  | MICA_CEN16_V3   | 1,00          | 0,90          | 0,90          |
| 1                  | MICA_CEN16_V4   | 1,00          | 0,91          | 0,91          |
| 1                  | MICA_CEN16_V5   | 1,00          | 0,89          | 0,89          |
| 1                  | MICA_CEN16_V6   | 1,00          | 0,91          | 0,91          |
| 2                  | MICA_CEN01_V1   | 1,00          | 0,54          | 0,54          |
| 2                  | MICA_CEN01_V2   | 1,00          | 0,70          | 0,70          |
| 2                  | MICA_CEN07_V5   | 0,52          | 0,84          | 0,67          |
| 2                  | MICA_CEN07_V6   | 0,50          | 0,88          | 0,65          |
| 2                  | MICA_CEN07_V7   | 0,50          | 0,91          | 0,65          |
| 2                  | MICA_CEN07_V8   | 0,50          | 0,87          | 0,64          |
| 2                  | MICA_CEN07_V9   | 0,51          | 0,88          | 0,66          |
| 2                  | MICA_CEN10_V1   | 0,94          | 0,58          | 0,56          |
| 2                  | MICA_CEN10_V2   | 0,86          | 0,62          | 0,60          |
| 2                  | MICA_CEN10_V3   | 0,93          | 0,67          | 0,66          |
| 2                  | MICA_CEN10_V4   | 0,84          | 0,58          | 0,53          |
| 2                  | MICA_CEN12_V1   | *             | *             | 0,51          |
| 2                  | MICA_CEN12_V2   | *             | 1,00          | 0,53          |
| 2                  | MICA_CEN12_V3   | *             | *             | 0,52          |
| <b>Média Geral</b> |                 | <b>0,7421</b> | <b>0,7638</b> | <b>0,6232</b> |

\* Imagens que não contém água nos recipientes do cenário.


Figura 24: Exemplos de resultados da RNA treinada com o (Conjunto Unificado)

### Conjunto 1


Cenário 01 – Todos os recipientes contendo água



(a) MICA\_CEN01\_V1 - Original – bandas R, G, B, NIR, EDG




(b) MICA\_CEN01\_V1\_ANOTADA




(c) MICA\_CEN01\_V1 - Classificada  
(precisão = 1,00)

### Conjunto 2


Cenário 01 – Todos os recipientes contendo água



(d) MICA\_CEN01\_V1 - Original – bandas R, G, B, NIR, EDG



(e) MICA\_CEN01\_V1\_ANOTADA



(f) MICA\_CEN01\_V1 - Classificada  
(precisão = 1,00)

Nas imagens classificadas mostradas nas figuras 24c e 24f ocorreram mais casos de FN, o que fez com que a sensibilidade média para fosse de 0,76 e 0,54 conforme detalhado na Tabela 8. Logo, a unificação dos conjuntos para treinamento prejudicou os resultados das classificações nas imagens para ambos os conjuntos nos objetos que contém água. Em contrapartida, ao analisar os resultados apenas para o conjunto 2 (Tabela 6), houve uma melhora nos resultados.

Com isso, a RNA-MLP treinada com dados extraídos dos dois conjuntos unificados no geral não foi melhor se comparada aos resultados da RNA-MLP treinada com o conjunto1, evidenciando que a unificação dos conjuntos prejudicou parcialmente seu desempenho final.


Contudo, ainda assim a abordagem proposta tem sua relevância visto a sua precisão para indicar a existência de água. O método proposto pode ser usado, por exemplo, para auxiliar na decisão de locais que necessitam de produtos químicos como pastilhas de inseticidas para contenção da proliferação dos mosquitos.

#### 4.3 DISCUSSÃO

Nos experimentos conduzidos o objetivo foi identificar se os recipientes possuíam água ou não, ou seja, apenas duas classes foram consideradas. Cabe destacar que foram realizados experimentos preliminares considerando 3 classes (cheio, metade e vazio), os quais indicaram que os recipientes cheios e com metade da sua capacidade preenchido com água possuíam características muito parecidas, induzindo o método de aprendizagem a cometer erros e, consequentemente, diminuindo seu desempenho. Tais experimentos foram extremamente relevantes para parametrização do algoritmo MLP para composição do método proposto.


Nos resultados reportados na seção 4.1 observou-se que alguns cenários que compuseram o Conjunto 1 possuíam reflexos de iluminação deixando as regiões da imagem muito mais claras do que as outras, como ilustrado na Figura 25, o que provavelmente prejudicou o treinamento da RNA-MLP.

Figura 25: Falhas nas classificações dos pixels devido à problemas de iluminação do ambiente – Treinamento com imagens do Conjunto 1



Todas as imagens mostradas na Figura 25 possuem claridade excessiva nos locais assinalados com uma janela na cor verde. Muitos dos pixels pertencentes à esses locais foram classificados não água (FN) quando na verdade todos os recipientes contêm água. Embora esse problema tenha sido minimizado no conjunto de dados unificado, ainda assim ocorreram classificações errôneas nas imagens, como pode ser visto na Figura 26.

Figura 26: Falhas nas classificações dos pixels devido à problemas de iluminação do ambiente – Treinamento com conjunto unificado



Talvez passos de pré-processamento das imagens, como normalização e filtragem, possam ser empregados para contornar as distorções de iluminação, principalmente se considerarmos que os ambientes reais não são controlados.


Outro problema observado foi a diferença dos tamanhos dos recipientes dos conjuntos 1 e 2. Na organização e definição do processo de aquisição das imagens no LABGEO foram definidos cenários diferentes com recipientes de tamanhos distintos. A ideia foi criar uma base de imagens que possibilitasse uma boa representatividade dos objetos suspeitos de serem potenciais criadouros de mosquitos, com e sem água.

Com base nos experimentos realizados foi possível observar que ao unificar os dois conjuntos de imagens a RNA-MLP melhora em alguns aspectos, como por exemplo, um melhor balanceamento nas classificações de água e não água, o que

possibilitou uma melhora na acurácia nos resultados da rede. Entretanto, para as métricas de sensibilidade e precisão, houve uma perda nos casos de recipientes que possuem água.

Na Figura 27 é possível verificar que as quantidades de pixels extraídos de ROIs de uma imagem do Conjunto 1 são bem maiores que as de ROIs de uma imagem do Conjunto 2. Ressalta-se que em ambas as aquisições foi considerada a mesma altura para posicionamento da câmera.

Figura 27: Diferença de tamanhos de recipientes dos conjuntos 1 e 2



A aquisição dessas imagens foi feita em ambiente controlado, obtendo imagens de boa qualidade que dificilmente em campo poderá ser superior as adquiridas, logo, realizar apenas ajustes da altura do drone em ambiente real para enriquecer os detalhes das imagens, dificilmente fará com que se obtenham melhores resultados. Assim, uma solução de contorno ainda precisa ser investigada para imagens obtidas em ambiente real.

Por fim, cabe ressaltar que o fato de terem sido empregados somente objetos circulares, para facilitar a delimitação das ROI e anotação das imagens, não traz prejuízo algum para o método proposto tendo em vista que quando ele for acoplado em uma aplicação (SVC) para identificação de focos de mosquitos, como ilustrado na Figura 28, a própria aplicação fornece como saída as delimitações das regiões da imagem que indicam focos, fazendo com que o método aqui proposto "saiba" quais pixels da imagem devem ser analisados.

Figura 28: Acoplamento do método proposto neste trabalho em um SVC para detecção de objetos e cenários suspeitos



É dessa maneira que o método proposto pode contribuir para o aumento da viabilidade técnica, econômica e ambiental do uso de drones no combate aos focos do mosquito *Aedes aegypti* e outros vetores.

## 5 CONCLUSÕES E PROPOSTA PARA TRABALHO FUTUROS

Neste trabalho foi proposto um método para detecção de pequenas porções d'água em objetos considerados potenciais criadouros de mosquitos. Para tanto, RNA do tipo *Multilayer Perceptron* (RNA-MLP) foi treinada para classificar os pixels de uma imagem a partir dos valores das bandas espectrais (*blue, green, red, Infra-red, RedEdge*).

Foram realizados experimentos com o objetivo de avaliar a utilização de 2 ('Água" e "Não Água") ou 3 classes (Cheio, Metade e Vazio). Constatou-se que os recipientes cheios e com metade da sua capacidade preenchido com água possuíam características muito parecidas, induzindo algoritmos de aprendizagem a erros. Com isso, optou-se pela utilização de apenas duas classes, considerando os recipientes preenchidos até a metade como cheios.

Outro passo importante foi o balanceamento dos dados de modo a não enviesar o algoritmo de aprendizagem, tendo em vista que há muito mais pixels da classe "Não Água". Apesar disso, ainda foram identificados problemas de balanceamento no momento dos testes, pois havia muitas imagens com recipientes sem água.

Também foram realizados experimentos para contornar o problema da alta correlação entre algumas das bandas espectrais. Assim, optou-se pelo uso do PCA, que permite a redução de dimensionalidade preservando as características mais importantes para a aprendizagem.

A escolha da RNA também foi baseada em experimentos nos quais foram avaliados alguns algoritmos bastante conhecidos na literatura, considerando modelos de classificação e de regressão.

A partir dos experimentos conduzidos neste trabalho verificou-se que a RNA-MLP obteve precisão média de 0,759 para o Conjunto 1, 0,554 para o Conjunto 2 e 0,742 para o conjunto unificado (características extraídas de imagens dos conjuntos 1 e 2). Também foram obtidas boas taxas de sensibilidade, sendo 0,944 para Conjunto 1; 0,986 para o Conjunto 2, e 0,763 para o conjunto unificado.

O principal problema identificado na avaliação da RNA-MLP ocorreu para o Conjunto 2, em virtude de os objetos serem bem menores nas imagens, levando a um menor conjunto de dados e prejudicando a etapa de aprendizagem da RNA-MLP. No entanto, isso foi parcialmente sanado com a unificação dos conjuntos, que possibilitou

uma melhora nas classificações das imagens do conjunto 2. Considerando que em ambientes reais não se pode controlar os cenários no momento de uma inspeção com o drone, o modelo de RNA-MLP deve ser treinado com dados que representem as variações de ambiente.

A possível solução de contorno para os principais problemas mencionados na seção 4.3 (iluminação não uniforme e tamanho muito reduzido dos objetos) é pré-processar as imagens visando uniformizar o brilho dos pixels; e realizar processo de redimensionamento das imagens as quais possuem objetos pequenos.

Por fim, pode-se dizer que os resultados atingidos pelo método proposto neste trabalho foram satisfatórios, pois a maior parte dos recipientes que possuíam água armazenada foram identificados corretamente, o que demonstra a contribuição desta pesquisa para tornar as abordagens existentes para detecção automática de potenciais criadouros de mosquitos mais eficazes. Tornar os drones mais efetivos no combate aos criadouros de mosquitos pode trazer contribuições para alguns dos Objetivos de Desenvolvimento Sustentável (ODS) estabelecidos pela Organização das Nações Unidas – ONU, como os ODS 3 (Saúde e Bem-Estar), 15 (Vida Terrestre) e 9 (Indústria, Inovação e Infraestrutura).

Em trabalhos futuros pretende-se: i) criar um conjunto de imagens adquiridas em ambientes reais; ii) conduzir novos experimentos com o objetivo de investigar formas de contornar os problemas identificados nesta pesquisa; iii) investigar a possibilidade de empregar Redes Neurais Convolucionais (RNC) para segmentação de regiões contendo água; IV) conduzir experimentos com Algoritmos Genéticos ou outra meta-heurística correlata visando a criação de um indicador para identificação das porções de água; V) acoplar o método proposto aos métodos identificação de objetos e cenários suspeitos e realizar experimentos em ambientes reais.

## REFERÊNCIAS

- AGARWAL, A.; CHAUDHURI, U.; CHAUDHURI, S.; SEETHARAMAN, G. **Detection of potential mosquito breeding sites based on community sourced geotagged images**. In: Geospatial InfoFusion and Video Analytics IV and Motion Imagery for ISR and Situational Awareness II, p. 90890M, 2014.
- AMARASINGHE, Akarshani; WIJESURIYA, Viraj B. **Drones vs dengue: a drone-based mosquito control system for preventing dengue**. In: 2020 RIVF International Conference on Computing and Communication Technologies (RIVF). IEEE, 2020. p. 1-6
- ARAGÃO, F. V.; ZOLA, F. C.; MARINHO, L. H. N.; DE GENARO CHIROLI, D. M.; JUNIOR, A. B.; & COLMENERO, J. C, **Choice of unmanned aerial vehicles for identification of mosquito breeding sites**. Geospatial Health, 15(1), 2020.
- BRAVO, D.T.; DE ARAUJO LIMA, S.J.; DE ARAUJO, S.A., ALVES, W.A.L. **Detection of Small Portions of Water in VIS-NIR Images Acquired by UAVs**. In: Vera-Rodriguez, R., Fierrez, J., Morales, A. (eds) Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. CIARP 2018. Lecture Notes in Computer Science(), vol 11401. Springer, Cham. [https://doi.org/10.1007/978-3-030-13469-3\\_20](https://doi.org/10.1007/978-3-030-13469-3_20). 2019.
- BRAVO, D. T. **Identificação automática de possíveis criadouros do mosquito aedes aegypti a partir de imagens aéreas adquiridas por vants**. 150 f. Tese (Doutorado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2019.
- BRAVO, D. T.; LIMA, G. A.; ALVES, W. A. L.; COLOMBO, V. P.; DJOGBÉNOU, L.; PAMBOUKIAN, S. V. D.; ... & DE ARAUJO, S. A. **Automatic detection of potential mosquito breeding sites from aerial images acquired by unmanned aerial vehicles**. Computers, Environment and Urban Systems, v. 90, 101692, 2021.
- CARRASCO-ESCOBAR, G.; MANRIQUE, E.; RUIZ-CABREJOS, J.; SAAVEDRA, M.; ALAVA, F.; BICKERSMITH, S.; ... & GAMBOA, D. **High-accuracy detection of malaria vector larval habitats using drone-based multispectral imagery**. PLoS neglected tropical diseases, 13(1), e0007105, 2019.

CORTES, Corinna.; VAPNIK, Vladimir (1995). **"Support-vector networks"** (PDF). Machine Learning. 20 (3): 273–297. CiteSeerX 10.1.1.15.9362. doi:10.1007/BF00994018. S2CID 206787478.

COTRIN, R. O.; PAMBOUKIAN, S. V. D.; QUARESMA, C. C.; ARAÚJO, S. A. **Towards an effective drone-based technology to combat mosquito breeding sites**. Proceedings of the joint XLIII Ibero-Latin-American Congress on Computational Methods in Engineering. Foz do Iguaçu, 2022. v. 1. p. 1-7.

DANTAS, C.G1 – O portal de notícias da Globo: **Consultoria estima que Brasil perdeu R\$ 2,3 bilhões em um ano com doenças do Aedes**. Disponível em: <https://g1.globo.com/bemestar/aedes-aegypti/noticia/consultoria-estima-que-brasil-perdeu-r-23-bilhoes-em-um-ano-com-doencas-do-aedes.ghtml>. Acesso em: 15 de agosto de 2021.

DA SILVA, G. L., & DE ASSIS BRITO FILHO, F. (2020). **Classificação do sinal mioelétrico utilizando Support Vector Machine e o modelo de Rede Neural Multilayer Perceptron**. Revista Ibérica de Sistemas e Tecnologias de Informação, (E28), 15-27

DIAS, T. M.; ALVES, V. C.; ALVES, H. M.; PINHEIRO, L. F.; PONTES, R. S. G.; ARAUJO, G. M.; ... & PREGO, T. M. (2018, November). **Autonomous detection of mosquito-breeding habitats using an unmanned aerial vehicle**. American Robotic Symposium, 2018 Brazilian Symposium on Robotics (SBR) and 2018 Workshop on Robotics in Education (WRE) (pp. 351-356). IEEE, 2018.

DINIZ, M. T. M.; MEDEIROS, J. B. **Mapping of breeding sites of aedes aegypti in Caicó/RN city with use of unmanned aerial vehicle**. Revista GeoNordeste, 2, 196–207, 2018.

FIOCRUZ MINAS (INSTITUTO RENÉ RANCHOU). **Dengue**. Disponível em: <http://www.cpqrr.fiocruz.br/pg/dengue/>. Acesso em: 23 de abril de 2022.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. 3ª Ed. São Paulo: Oficina de Textos, 2011. Disponível em: [http://books.google.com.br/books/about/Inicia%C3%A7%C3%A3o\\_em\\_Sensoriamento\\_Remoto.html?hl=pt-BR&id=18GkH5X81XcC](http://books.google.com.br/books/about/Inicia%C3%A7%C3%A3o_em_Sensoriamento_Remoto.html?hl=pt-BR&id=18GkH5X81XcC). Acesso em: 23 agosto de 2023. GERS–Governo Estadual do Rio Grande do Sul. **Arboviroses**. Disponível em: <https://atencaobasica.saude.rs.gov.br/arboviroses#:~:text=As%20arboviroses%20co>

mo%20dengue%2C%20Chikungunya,das%20popula%C3%A7%C3%B5es%20do%20Aedes%20aegypti. Acesso em: 23 de abril de 2022.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning: The MIT Press, 2016.

GRUBESIC, T. H., WALLACE, D., CHAMBERLAIN, A. W., & NELSON, J. R. (2018). **Using unmanned aerial systems (UAS) for remotely sensing physical disorder in neighborhoods.** Landscape and Urban Planning, 169, 148-159. <https://doi.org/10.1016/j.landurbplan.2017.09.00>

HAAS-STAPLETON, E. J.; BARRETTO, M. C.; CASTILLO, E. B.; CLAUSNITZER, R. J.; & FERDAN, R. L. **Assessing Mosquito Breeding Sites and Abundance Using An Unmanned Aircraft.** Journal of the American Mosquito Control Association, 35(3), 228-232, 2019.

HADDAWY, P.; WETTAYAKORN P, NONTHALEERAK B, SU YIN M, WIRATSUDAKUL A, SCHO'NING J. **Large scale detailed mapping of dengue vector breeding sites using street view images.** 2019.

HARDY, A.; MAKAME, M.; CROSS, D.; MAJAMBERE, S.; & MSELLEM, M. **Using low-cost drones to map malaria vector habitats,** 2017.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. The Elements of Statistical Learning (2nd ed.). Springer. ISBN 0-387-95284-5. 2008.

HO, Tin, Kam. **Florestas de decisão aleatória.** Anais da 3ª Conferência Internacional sobre Análise e Reconhecimento de Documentos, Montreal, QC, 14–16 de agosto de 1995.

JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. **Artificial neural networks:** A tutorial. IEEE Computer, v. 29, n. 3, p. 31-44, 1996.

JAIN, A. K.; DUIN, R. P. W.; MAO, J. **Statistical pattern recognition:** A review. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 22, n. 1, p. 4-37, 2000.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. **Data clustering:** a review. ACM Comput. Surv., v. 31, n. 3, p. 264-323, 1999.

KUMAR, V. **An approach for global monitoring of surface water extent variations in reservoirs using MODIS data.** Remote Sensing Environment, 202:113-128, 2017.

LABGEO - Laboratório de Geotecnologias da Universidade Presbiteriana Mackenzie.

**Sensoriamento Remoto.** Disponível em:

[https://www.mackenzie.br/fileadmin/OLD/62/ARQUIVOS/PUBLIC/user\\_upload/imported/fileadmin/LABGEO/Curso/08. Aula 08/0803. Sensoriamento Remoto.pdf](https://www.mackenzie.br/fileadmin/OLD/62/ARQUIVOS/PUBLIC/user_upload/imported/fileadmin/LABGEO/Curso/08. Aula 08/0803. Sensoriamento Remoto.pdf).

Acesso em: 29 de agosto de 2023.

MEHRA, M.; BAGRI, A.; JIANG, X.; ORTIZ, J. **Image analysis for identifying mosquito breeding grounds.** In: 2016 IEEE International Conference on Communication and Networking (SECON Workshops), 1–6, 2016.

MICASENSE - **RedEdge MX. Sistema de Câmera Dual.** Disponível em: <https://micasense.com/pt-br/sistema-de-camera-dual/>. Acesso em: 14 abr. 2022.

MINAKSHI. M.; BHUIYAN. T, KARIEV. S.; KADDUMUKASA. M.; LOUM. D.; STANLEY. N.B.; CHELLAPPAN. S.; HABOMUGISHA. P, OGUTTU. D.W., JACOB. B.G. **HIGH-ACCURACY detection of malaria mosquito habitats using drone-based multispectral imagery and Artificial Intelligence (AI) algorithms in an agro-village peri-urban pastureland intervention site (Akonyibedo) in Unyama Sub-County, Gulu District, Northern Uganda.** Journal of Public Health and Epidemiology, 12(3), pp. 202-217, 2020.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of ideas immanent in nervous activity.** Bulletin of Mathematical Biophysics, v. 5, p. 115-133, 1943.

MITCHELL, T.M. **Machine Learning.** Published October 1st 1997 by McGraw-Hill (first published April 30th 1986), 1997.

MONTEIRO, L. **MÉTODOS DE PESQUISA.** Disponível em: [file:///C:/Users/rafael.cotrin/Documents/Mestrado/Disciplinas/Methodology%20Research/Metodos\\_de\\_pesquisa.pdf](file:///C:/Users/rafael.cotrin/Documents/Mestrado/Disciplinas/Methodology%20Research/Metodos_de_pesquisa.pdf). Acesso em: 01 jun. 2022.

MS - MINISTÉRIO DA SAÚDE. **Aedes Aegypti.** Disponível em: <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/a/aedes-aegypti>. Acesso em: 18 jun. 2022a.

MS - MINISTÉRIO DA SAÚDE. **Informe Semanal COE Arboviroses 07/06.** Disponível em: <https://www.gov.br/saude/pt-br/composicao/svsa/resposta-a-emergencias/coes/arboviroses/atualizacao-dos-casos/informe-semanal-coe-arboviroses-07-06/view>. Acesso em: 07 ago. 2023.

MS – MINISTÉRIO DA SAÚDE. **Brasil integra debate da OMS sobre iniciativa global de controle das arboviroses**. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/noticias/2022/marco/brasil-integra-debate-da-oms-sobre-iniciativa-global-de-controle-das-arboviroses>. Acesso em: 18 jun. 2022b.

MS – MINISTÉRIO DA SAÚDE. **Combate ao Mosquito Aedes Aegypti**. Disponível em: <https://www.gov.br/saude/pt-br/campanhas-da-saude/2022/combate-ao-mosquito-aedes-aegypti-2021-2022>. Acesso em: 18 jun. 2022c.

NORVIG, Peter. **Inteligência Artificial**. Grupo GEN, 2013. E-book. ISBN 9788595156104. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788595156104/>. Acesso em: 03 set. 2023.

OMS – ORGANIZAÇÃO MUNDIAL DA SAÚDE. **Doenças transmitidas por vetores**. (2020). Disponível em: <https://www.who.int/es/news-room/fact-sheets/detail/vector-borne-diseases>. Acesso em: 17 fev. 2021.

OMS – ORGANIZAÇÃO MUNDIAL DA SAÚDE. **Dengue y dengue grave**. (2023). Disponível em: <https://www.who.int/es/news-room/fact-sheets/detail/dengue-and-severe-dengue>. Acesso em: 07 ago. 2023.

ONU – ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **OMS: Brasil é o país mais afetado em novo surto de dengue nas Américas**. (2023). Disponível em: <https://news.un.org/pt/story/2023/07/1817882>. Acesso em: 07 ago. 2023.

PAHO – ORGANIZAÇÃO PAN-AMERICANA DE SAÚDE. **À medida que os casos de dengue aumentam globalmente, o controle de vetores e o envolvimento da comunidade são essenciais para evitar a propagação da doença**. Disponível em: <https://www.paho.org/en/news/3-8-2023-dengue-cases-increase-globally-vector-control-community-engagement-key-prevent-spread>. Acesso em: 08 ago. 2023.

PASSOS, W. L.; DIAS, T. M.; ALVES JUNIOR, H. M.; BARROS, B. D.; ARAUJO, G. M.; LIMA, A. A.; SILVA, E. A. B.; & LIMA NETTO, S. **About Automatic Detection of Aedes aegypti Mosquito Focuses**. In: Anais do XXXVI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 1–5, 2018.

PASSOS, W. L.; DA SILVA E. A.; NETTO, S. L.; ARAUJO, G. M.; & DE LIMA, A. A. Automatic Detection of Aedes aegypti Breeding Grounds Based on Deep Networks with Spatio-Temporal Consistency. arXiv preprint arXiv:2007.14863, 2020.

POLIDORIO, A. M.; IMAI, N. N; TOMMASELLI, A. M. G. **Índice indicador de corpos d'água para imagens multiespectrais**. In: I Simpósio de Ciências Geodésicas e Tecnologias da Geoinformação. 9, Recife-PE, 2014.

PRASAD, M. G.; CHAKRABORTY, A.; CHALASANI, R.; & CHANDRAN, S. **Quadcopter-based stagnant water identification**. In 2015 Fifth National Conference on Computer Vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG) (pp. 1-4). IEEE, 2015.

ROSSI, L.; BACKES, A. R.; SOUZA, J. R. **Rain Gutter Detection in Aerial Images for Aedes aegypti Mosquito Prevention**. In: Anais do XVI Workshop de Visão Computacional, 1-5, 2020.

RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel distributed processing**, v. 1. The MIT Press, 576 p., 1986.

RUSSEL, S.; NORVIG, P. Inteligência artificial. 2. ed. Rio de Janeiro: Campus, 2004.

SCHENKEL. J.; TAELE. P.; GOLDBERG. D.; HORNEY. J.; & HAMMOND. T. **Identifying Potential Mosquito Breeding Grounds: Assessing the Efficiency of UAV Technology in Public Health**. Robotics, 2020.

SESA – Secretaria de Estado da Saúde (Governo do Estado do Espírito Santo). **Mosquito - Aedes aegypti**. Disponível em: <https://mosquito.saude.es.gov.br/aedes-aedypti>. Acesso em: 23 abr. 2022.

SILVA, I. **Detecção automática da presença de patologia na visão baseada em imagens do teste de Brückner**. Dissertação de Mestrado. Ciência da Computação da Universidade Federal do Maranhão. UFMA, 2019.

STANTON, M. C.; KALONDE, P.; ZEMBERE, K.; SPAANS, R. H.; & JONES, C. M. **The application of drones for mosquito larval habitat identification in rural environments: a practical approach for malaria control**. Malaria journal, 20(1), 1-17, 2021.

SUDUWELLA, CHATHURA AMARASINGHE, AKARSHANI & NIROSHAN, LASITH & ELVITIGALA, CHARITH DE ZOYSA, KASUN & KEPPETIYAGAMA, CHAMATH. **Identifying Mosquito Breeding Sites via Drone Images**. 27-30, 2017.

TRUJILLANO, Fedra et al. Mapping Malaria Vector Habitats in West Africa: Drone Imagery and Deep Learning Analysis for Targeted Vector Surveillance. Remote sensing, v. 15, n. 11, p. 2775, 2023.

VIANA, G. V. R. Meta-heurísticas para Problemas de Otimização Combinatória. Revista Científica da Faculdade Lourenço Filho - v.9, n.1, 2013

YANG, X.; CHEN, L. **Evaluation of automated urban surface water extraction from Sentinel-2A imagery using different water indices**. Journal of Applied Remote Sensing, 11, 026016, 201

