

Aplicação de Aprendizagem de Máquina na estimação do número de ovos de Aedes em imagens de ovitrampas

Lucas Veit de Sá
Universidade Estadual
do Oeste do Paraná
Cascavel, PR, Brasil
lucas-cs1998@hotmail.com
orcid: 0000-0002-5261-2012

Claudia Brandelero Rizzi
Universidade Estadual
do Oeste do Paraná
Cascavel, PR, Brasil
claudia.rizzi@unioeste.br
orcid: 0000-0003-0739-9117

Rogério Luís Rizzi
Universidade Estadual
do Oeste do Paraná
Cascavel, PR, Brasil
rogerio.rizzi@unioeste.br
orcid: 0000-0001-9895-1012

André Luiz Brun
Universidade Estadual
do Oeste do Paraná
Cascavel, PR, Brasil
andre.brun@unioeste.br
orcid: 0000-0003-2357-9425

Abstract—Dengue fever is a disease that can be fatal and is found in more than one hundred countries. One approach to control the endemic disease is to reduce the transmission vector, the Aedes mosquitoes. Therefore, it is necessary to control their reproduction. The present work attempts to automate the task of identifying and counting Aedes mosquito eggs in digitized images of ovitraps. To this end, one image was used for training and five images were used for testing, applying five different machine learning approaches to classify the pixels of each image as egg or background. Then, egg counting was performed based on the number of pixels classified as egg in a region. After counting, the five approaches were compared based on the mean relative error. The technique that achieved the best result was the K-nearest neighbor algorithm with an average relative error of 15.85%. MLP was the second best approach with an average error of 16.02%. The worst result was provided by the Bootstrap Aggregating technique, whose average relative error was 17.74%.

Resumo—A dengue é uma doença que pode ser letal que está presente em mais de cem países. Uma abordagem utilizada para seu controle endêmico é a redução do vetor de transmissão, os mosquitos da espécie Aedes. Desse modo, faz-se necessário o controle da proliferação deles. O presente trabalho busca automatizar a tarefa de identificação e contagem de ovos de mosquitos da espécie Aedes em imagens digitalizadas de ovitrampas. Para isso, foi utilizada uma imagem para treino e cinco imagens para teste, onde aplicou-se cinco diferentes abordagens de aprendizagem de máquina para classificação dos pixels de cada imagem como ovo ou fundo e, em seguida, foi realizada a contagem de ovos baseado no número de pixels classificados como ovo em uma área. Após a contagem, as cinco abordagens foram comparadas pelo erro médio relativo. A técnica que obteve o melhor resultado foi o algoritmo K-Nearest Neighbors, com erro médio relativo de 15,85%. O MLP, com um erro médio de 16,02% foi a segunda melhor abordagem. Já o pior resultado foi apresentado pela técnica de Bootstrap

Aggregating, cujo erro médio relativo foi de 17,74%.

Palavras-chave—contagem automática; dengue; reconhecimento de padrões.

I. INTRODUÇÃO

A dengue é uma doença febril aguda presente em mais de cem países, principalmente em regiões próximas à Linha do Equador e em quadro de subdesenvolvimento. Isso ocorre visto que as características climáticas e ambientais são propícias ao Aedes, vetor da doença [1]. Além disso, as condições socioeconômicas podem influenciar uma vez que caso não seja feito o devido acompanhamento, o acúmulo de materiais como pneus, plásticos, reservatórios descobertos podem favorecer o mosquito, servindo-lhe de criadouros.

Segundo a Organização Mundial de Saúde (OMS), mais de 50 milhões de pessoas são contaminadas todos os anos, das quais 500 são diagnosticadas como dengue hemorrágica. A entidade aponta que cerca de 20 mil pessoas morrem anualmente em decorrência da doença. Conforme [2], cerca de 70% dos casos da doença ocorrem na Ásia, principalmente na Índia. Ainda segundo a OMS, acredita-se que aproximadamente 2,5 bilhões de pessoas estejam em risco de contrair a doença.

No Brasil estão presentes quatro sorotipos da dengue (DENV-1, DENV-2, DENV-3 e DENV-4) e todos podem causar enfermidades graves e mortais. Os sintomas mais comuns são as dores de cabeça e no corpo, febre alta, dor nas articulações e atrás dos olhos, fraqueza e prurido [3]. Segundo dados da Organização Pan-Americana de Saúde [4], no ano de 2022 foram registrados 2.014.352 casos suspeitos no país, dos quais

1.278 de pacientes graves. Além disso, até a presente data foram observados 801 óbitos.

Segundo [5], a dengue é causada por um arbovírus do gênero Flavivírus. Diversas espécies de mosquitos *Aedes* podem servir de vetor para a doença. No Brasil, o *Aedes albopictus* e, principalmente, o *Aedes aegypti*, são as duas espécies responsáveis pela transmissão da doença.

Embora uma vacina contra a dengue exista (Dengvaxial, do laboratório Sanofi-Aventis), aprovada no Brasil em 2015, ela precisa ser aperfeiçoada por diversos motivos, como o fato de que não é recomendada para indivíduos soronegativos. Além dos casos assintomáticos, como nem todos os indivíduos sabem efetivamente se contraíram ou não dengue, trata-se de um problema sério no que tange à vacinação em massa [6]. Neste sentido ainda são mais recomendadas ações objetivando o controle do vetor.

Estes procedimentos tentam diminuir a população do mosquito atacando as diversas fases em que ele se apresenta. Políticas são fundamentais. Exemplos são o estímulo à limpeza constante em receptáculos que podem se tornar criadouros do mosquito, aplicação pontual de inseticida onde há larvas e pupas e, apenas em última instância nos casos de epidemias, pulverização em aéreas específicas para o combate do *Aedes* na fase alada.

Uma das abordagens mais eficientes para detecção, estimação e monitoramento do vetor é através da contagem de ovos presentes em uma determinada localização [7]. Segundo os autores, a partir levantamento do número de ovos pode-se estimar a quantidade de vetores que chegarão às fases seguintes de larva, pupa e alada (ou adulta).

A ovitrampa é uma espécie de armadilha usada para coletar ovos de mosquito. Elas são formadas por um recipiente plástico, geralmente preto fosco o qual é parcialmente preenchido por água ou por algum tipo de infusão que tem a função de atrair a fêmea para a oviposição, e uma lâmina (ou placa) com superfície rugosa posicionada de forma que fique parcialmente submersa [8]. A placa normalmente é composta de compensado de madeira, algodão ou papel filtro. Na Figura 1 é apresentada a estrutura de uma ovitrampa. Na ilustração pode-se perceber que a lâmina, presa à borda do recipiente, está parcialmente imersa.

Inicialmente as ovitrampas são posicionadas em locais em que há vetores e, após certo intervalo de tempo (geralmente 7 dias), as lâminas são substituídas por outras novas e o processo de contagem é realizado. A Figura 2 apresenta o segmento de imagem de uma lâmina contendo ovos de *Aedes aegypti*. Os diversos artefatos alongados de coloração mais escura são os ovos da fêmea do mosquito.

A contagem dos ovos, muitas vezes, é feita de forma manual, utilizando-se de algum mecanismo de microscopia para auxiliar

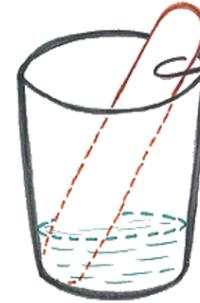


Fig. 1. Ilustração de uma ovitrampa. Fonte: [9]



Fig. 2. Segmento de imagem digital de uma lâmina proveniente de ovitrampa. Fonte: [10], [11]

na visualização das placas. Porém, como apontado por [12], esse processo é bastante exaustivo e sujeito a falhas já que exige um esforço visual contínuo do responsável. Além disso, há o problema da interpretação humana de cada objeto, podendo levar a contagens com valores distintos.

Uma estratégia encontrada para mitigar os desafios apresentados pela contagem manual dos ovos do *Aedes* é a adoção de uma abordagem computacional, dado que o computador não sofre da exaustão e, como possui comportamento determinístico, pode ser empregado de forma contínua na contagem. A adoção de computadores no processo, no entanto, deve ser tratada de forma bastante cuidadosa, principalmente dados os fatores de influência na contagem automática, tais como a presença de ruídos, diferentes resoluções de imagem, distância focal das lâminas, material de composição da lâmina, iluminação, entre outros.

Assim sendo, neste trabalho propomos e avaliamos a aplicação de estratégias de aprendizagem de máquina como estratégia de contagem automática do número de ovos de *Aedes* em imagens digitais de lâminas de ovitrampas. Para tanto, foram implementadas cinco diferentes estratégias de classificação, três delas baseadas em sistemas monolíticos (*Multi-layer Perceptron*, *Support Vector Machines* e *K-Nearest Neighbors*) e duas baseadas em sistemas de múltiplos classifi-

cadadores (SMC): *Random Forest* (RF) e *Bootstrap aggregating* (Bagging).

II. METODOLOGIA

O processo de contagem automática dos ovos de *Aedes* foi dividido em duas etapas. Na primeira, treinamento, uma imagem foi empregada para extração das características e treinamento dos modelos de classificação para aprender a reconhecer quais são os pixels referentes aos ovos e quais são pixels de fundo. Na segunda fase, operacional, novas imagens são fornecidas ao sistema, suas características são extraídas e cada pixel é classificado. Com base nessa classificação é então realizada a estimação do número de ovos presentes na imagem de teste. Cada etapa será melhor detalhada nas seções seguintes.

A. Treinamento

O objetivo desta fase é capacitar os modelos de reconhecimento a conseguir diferenciar os objetos de interesse do fundo da imagem. Para tanto, são necessárias características suficientemente discrepantes que permitam aos classificadores fazerem essa identificação. O processo de treinamento é ilustrado na Figura 3.

No primeiro passo (1) uma imagem escolhida ao acaso e que tenha as mesmas características das demais é escolhida para a construção do conjunto de treinamento. Cada um dos pixels que representam ovos presentes na imagem foram identificados manualmente para que pudéssemos realizar um aprendizado supervisionado. Tais pixels são destacados na figura.

O passo seguinte (2), consiste em varrer todos os pixels da imagem selecionada anteriormente e extrair um conjunto de características para cada elemento para compor o conjunto de dados a ser usado para treinar os modelos de classificação. Neste sentido, o conjunto de treinamento foi composto por $n \times m$ instâncias, em que n e m referem-se à largura e altura da imagem, respectivamente.

As características obtidas a partir de cada pixel correspondem aos valores dos seus canais H (*Hue*), S (*Saturation*) e V (*Value*), bem como os valores médios dos canais H, S e V da sua vizinhança para a qual foi adotado um critério de 8-conectividade. Ou seja, para cada posição foram selecionados todos os oito pixels ao seu redor para o cálculo da média dos três canais. Além dos valores médios foram estimados os desvios padrões para cada um dos três elementos, H, S e V. Assim, o vetor de características obtido é composto de nove atributos, três referentes a ele próprio e seis baseados na sua vizinhança. É então adicionada a classe à instância construída, identificando se ela pertence à classe ovo ou ao fundo da imagem. Essa estratégia baseou-se no trabalho de [13].

Construído o *dataset*, fez-se a divisão do mesmo em conjunto de treino e validação (3). O primeiro, que recebeu 70% das

instâncias do grupo original, é utilizado para o aprendizado dos modelos. Já o segundo, cujo tamanho corresponde aos 30% restantes, é empregado na calibração dos parâmetros dos modelos. Importante destacar que a divisão entre os dois conjuntos foi realizada de forma estratificada, mantendo-se as proporções originais entre as classes.

A imagem utilizada para a extração das características tem 302 pixels de largura e 290 de altura. Assim, o *dataset* formado consiste em 87.580 instâncias, das quais 6974 compõe a classe ovo enquanto 80.606 formam o conjunto de pixels que representam o fundo.

No quarto passo (4) os modelos de classificação escolhidos foram treinados e submetidos ao processo de *grid search* para refinamento dos seus parâmetros. Foram selecionados aqueles que levaram à maior acurácia sobre o conjunto de validação.

Para a classificação dos pixels foram implementadas cinco estratégias, das quais três consistem em métodos monolíticos, que são aqueles em que um único classificador é responsável por atribuir as classes a todas as instâncias do conjunto. As abordagens adotadas foram o MLP (*Multipayer Perceptron*), o SVM (*Support Vector Machine*) e o KNN (*K-Nearest Neighbors*).

Entretanto, nem sempre uma abordagem monolítica é capaz de absorver toda a variabilidade de um problema. Uma tentativa de mitigar tal desafio é a adoção de múltiplos classificadores trabalhando em conjunto, os Sistemas de Múltiplos Classificadores (SMC). Nessa estratégia, diversos classificadores são treinados em conjuntos de dados distintos (sistema homogêneo) ou com base em diferentes modelos de aprendizagem (sistema heterogêneo) e suas opiniões são combinadas visando obter resultados mais consistentes frente à solução de classificador único [14]–[16]. As estratégias de múltiplos classificadores empregadas foram o *Random Forest* (RF) e o Bagging (*Bootstrap Aggregating*).

A Tabela I apresenta os modelos avaliados no estudo (primeira coluna) bem como o detalhamento de quais parâmetros foram variados durante o *grid search* (coluna central) e, na última coluna, os valores testados para cada parâmetro.

Na segunda tabela são identificadas as configurações dos parâmetros que levaram à melhor taxa de acertos sobre o conjunto de validação. Tais valores foram então empregados na etapa de avaliação.

B. Etapa operacional

O processo de avaliação das abordagens implementadas deu-se sobre um conjunto composto de cinco imagens com características similares àquelas da imagem empregada no treinamento. A única variação refere-se às dimensões, uma vez que cada uma possui largura e altura distintas. Todas

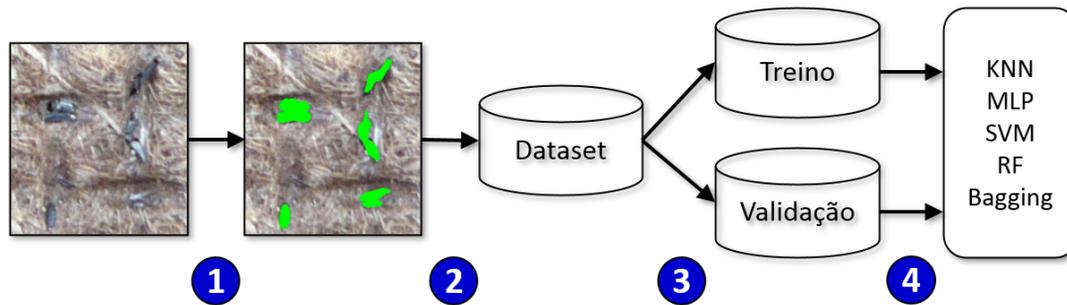


Fig. 3. Fluxograma do processo de extração de características e treinamento dos classificadores.

TABELA I
CONFIGURAÇÕES TESTADAS DURANTE O GRID SEARCH

Modelo	Parâmetros	Valores Testados
KNN	K weights	{1, 2, 3, 4, ..., 28, 29, 30} {uniform, distance}
MLP	max_iter activation learning_rate learning_rate_init número de camadas escondidas número de nós por camada escondida	{100, 200, 300, 400, 500, 600, 700, 800, 900, 1000} {relu, logistic} {constant} {0.01, 0.02, 0.03, ..., 0.19, 0.20 } {3, 5, 7} {7, 9, 11, 13}
SVM	C kernel	{0.1, 0.2, 0.3, ..., 0.9, 1} {linear, poly1, rbf}
RF	n_estimators min_samples_leaf	{10, 20, 30, ..., 80, 90, 100, 200, 300, ..., 800, 900, 1000, 2000, 3000, 5000} {2, 3, 4, ..., 8, 9, 10}
Bagging	n_estimators estimators	100 {MLP, SVM, DT}

TABELA II
MELHOR CONFIGURAÇÃO PARA CADA MODELO

Modelo	Parâmetros
KNN	K = 14 weights = distance
MLP	max_iter = 200 activation = relu learning_rate_init = 0.01 learning_rate = constant número de camadas escondidas = 3 número de nós por camada escondida = 13
SVM	C = 1 kernel = rbf
RF	n_estimators = 5000 min_samples_leaf = 2
Bagging	n_estimators = 100 estimators = DT

e terceira coluna apresentam a largura e altura da imagem enquanto a quarta coluna detalha o número de ovos presentes em cada uma. Tal valor foi obtido através de contagem manual realizada durante os experimentos dos autores citados anteriormente. A coluna mais à direita indica se aquela imagem foi usada no treinamento ou avaliação dos métodos.

TABELA III
DESCRIÇÃO DAS IMAGENS UTILIZADAS NOS EXPERIMENTOS.

Imagem	Largura	Altura	Número de ovos	Aplicação
0	302	290	22	Treino
1	194	210	8	Teste
2	555	456	111	Teste
3	190	258	30	Teste
4	186	241	19	Teste
5	141	127	0	Teste

as imagens empregadas nesta pesquisa são provenientes das pesquisas de Mello *et al.* [11] e Portela *et al.* [9], [10] e foram disponibilizadas pelos pesquisadores. Na Tabela III são apresentados detalhes de cada imagem empregada. A primeira coluna corresponde ao identificador de cada entrada. A segunda

As imagens fornecidas nesta etapa (imagens de 1 a 5) foram submetidas ao mesmo processo de extração de características da imagem de treino. Assim, cada entrada foi transformada em um conjunto de dados contendo de $n \times m$ instâncias, em que n refere-se à largura e m à altura da imagem. Cada instância

é composta pelos mesmos nove atributos (valores H, S e V do pixel, média dos valores H, S e V dos 8 vizinhos e os desvios padrão dos canais H, S e V da mesma vizinhança). Por representarem o conjunto de avaliação, os classificadores não conhecem a classe a que pertencem cada um dos pixels.

As cinco estratégias de aprendizagem de máquina implementadas foram aplicadas a cada uma das cinco imagens de teste para classificar seus pixels como elemento pertencente a um ovo ou fundo da imagem. Acreditamos que a técnica que conseguisse identificar com mais precisão os elementos dos dois grupos teria uma estimativa mais precisa do número de ovos presentes em cada imagem.

Ao término da execução cada entrada é representada por uma imagem binarizada, consistindo nas duas classes do problema. O passo seguinte é a estimativa do número de ovos presentes. Para tanto, faz-se a análise dos componentes conectados, representados pelos grupos de pixels classificados como ovos. Cada componente teve seu número de pixels contados e então divididos por um limiar empiricamente determinado. Neste estudo adotou-se $T = 263$. Tal valor representa o tamanho médio de um ovo de *Aedes* para as imagens empregadas no estudo.

III. RESULTADOS E DISCUSSÕES

A primeira avaliação realizada é baseada no comportamento da curva ROC de cada técnica sobre o conjunto de imagens de teste. A curva ROC, segundo [17], é uma ferramenta útil e poderosa na avaliação de modelos de classificação. Além disso, ela é particularmente útil em domínios nos quais existe uma grande desproporção entre as classes, fato observado no presente estudo, uma vez que o número de amostras que representam o conjunto de fundo corresponde a cerca de 90% do total de pixels.

A análise da curva ROC permite comparar os desempenhos de diversos modelos. O critério adotado, para tanto, consiste na área sob a curva ou AUC (*Area Under the Curve*). O índice, em que $AUC \in [0, 1]$, reflete diretamente a qualidade do modelo. Quanto maior o valor da área, melhor é o modelo de classificação.

Para cada uma das entradas calculou-se o valor da AUC frente todas as estratégias. Os desempenhos obtidos pelas cinco abordagens são detalhados na Tabela IV. Na coluna mais à direita são apresentados os valores médios da AUC das cinco imagens de teste para cada método avaliado. Os valores em negrito correspondem ao melhor desempenho para cada entrada. A imagem 5, por não conter ovos, inviabilizou o cálculo da área sob a curva, já que o conjunto é composto de apenas uma classe.

Os resultados obtidos para a AUC mostraram-se bastante próximos. Como observado, para cada imagem de entrada um

TABELA IV
VALORES DA ÁREA SOB A CURVA OBTIDOS NA IDENTIFICAÇÃO DA CLASSE DE CADA PIXEL DAS IMAGENS

Método	AUC Individual					AUC Média
	Img 1	Img 2	Img 3	Img 4	Img 5	
KNN	0.8603	0.8265	0.8783	0.8173	–	0.8456
MLP	0.8534	0.8009	0.8865	0.7960	–	0.8342
SVM	0.8453	0.8279	0.8807	0.8074	–	0.8403
RF	0.8604	0.8116	0.8797	0.8189	–	0.8427
Bagging	0.8613	0.8065	0.8684	0.8160	–	0.8381

método distinto apresentou o maior valor de área sob a curva. Um fato interessante é que o KNN, apesar de não ter obtido o maior valor de AUC para nenhuma das imagens, foi o modelo de maior área média entre as cinco abordagens, mostrando-se o mais promissor.

Após a execução do processo de classificação dos pixels é então realizada a análise dos componentes conectados. Cada conjunto de pixels vizinhos que pertencem à classe ovo são agrupados. A seguir a quantidade de ovos é determinada pela divisão do número total de pixels do grupo pelo patamar definido a priori ($T = 263$).

Na Tabela V são apresentados o número real de ovos de *Aedes* (última linha) e a quantidade estimada por cada técnica para cada uma das cinco imagens de teste. Neste cenário, consideramos que uma superestimação ou subestimação têm o mesmo peso e, para tanto, o erro foi considerado como valor absoluto. O erro relativo é calculado dividindo-se o erro pelo Valor Real de cada imagem. O processo de cálculo é dado pela Equação 1. Os termos x_{true} e x_{test} correspondem, respectivamente, ao número real de ovos presentes na imagem e ao número estimado pela técnica.

$$ER = \frac{x_{true} - x_{test}}{1 + x_{true}} \quad (1)$$

A ideia de calcular o erro relativo para cada imagem deu-se para tentar levar em conta o peso do número de ovos presentes em uma imagem. Por exemplo, caso uma técnica erre sua estimativa de quantidade de ovos em 9 unidades para uma imagem que contém 111 ovos, seu percentual de erro seria de 8,03%. Por outro lado, caso a imagem contivesse 30 ovos, seu erro seria de 26,79%. Dessa forma, para obtermos então o Erro Relativo Médio (ERM) do método basta calcularmos a média entre os erros percentuais de todas as imagens do conjunto. Tais valores são apresentados na última coluna da Tabela V.

Analisando-se os valores obtidos pelas cinco estratégias de classificação podemos perceber que o KNN foi quem obteve o menor erro relativo (15,85%). A segunda melhor abordagem foi o perceptron de múltiplas camadas (16,02%), seguida pelo

TABELA V
QUANTIDADE DE OVOS ESTIMADOS POR CADA ESTRATÉGIA PARA TODAS
AS IMAGENS DE TESTE.

Método	Quantidades estimadas para cada imagem					ERM
	Img 2	Img 3	Img 4	Img 5	Img 6	
KNN	5	106	28	12	0	15,55%
MLP	6	91	30	11	0	16,02%
SVM	5	106	26	12	0	17,14%
RF	5	101	27	12	0	17,39%
Bagging	5	99	27	12	0	17,74%
Valor real	8	111	30	19	0	

SVM com erro médio de 17,14%. O pior desempenho foi obtido pelo Bagging, com 17,74% de ERM.

De forma geral, pode-se perceber que todas as estratégias de classificação avaliadas apresentaram valores subestimados para a quantidade de ovos presentes (com exceção à quinta entrada que não possuía ovos). Tal fato pode indicar a necessidade de uma melhor calibragem no limiar T usado para definir o número de ovos presentes em cada componente conectado.

Ao avaliarmos o erro médio apresentado para cada imagem de teste percebe-se que a imagem 5 não sofreu com erros de estimação dos classificadores uma vez que nenhum deles indicou a presença de ovos nela. As imagens 2 e 3 apresentaram um erro relativo médio de 8,93% e 7,26%, respectivamente. Por outro lado, as imagens 1 e 4 sofreram com estimativas mais pobres. A primeira imagem apresentou um ERM de 30,56%. Já a imagem 4, com um erro médio de 36,25% foi a entrada que mais sofreu com as classificações adotadas.

IV. CONCLUSÃO

A dengue é considerada uma das doenças mais importantes atualmente, contaminando anualmente mais de 50 milhões de pessoas e colocando em risco a vida de outros 2,5 bilhões. Como ainda não há uma vacina eficaz contra a enfermidade, a abordagem mais efetiva é o combate ao vetor e uma das formas de efetivar esse enfrentamento é estimando o número de mosquitos transmissores presentes em cada localidade. Para tanto podem ser empregadas as ovitrampas.

O processo de contagem dos ovos para se estimar a população do *Aedes* é um processo oneroso e suscetível a falhas humanas. Para tanto, foram propostas e avaliadas cinco estratégias baseadas em algoritmos de aprendizagem de máquina para a contagem automática do número de ovos presentes em imagens de ovitrampas. Foram implementados um algoritmo KNN, uma rede neural MLP, uma máquina de vetores de suporte e duas estratégias de classificação múltipla, o Bagging e o Random Forest.

Todas as implementações foram avaliadas sobre um conjunto composto por cinco imagens e, com base no erro relativo médio, o KNN foi a abordagem que pôde estimar o número de

ovos com a maior precisão. A estratégia apresentou um ERM de 15,85%. O segundo método mais preciso foi o MLP, com um erro de 16,02%. O pior desempenho foi obtido pelo Bagging, com 17,74% de erro.

Os resultados mostraram a viabilidade da adoção das estratégias propostas. No entanto, ainda há espaço para melhoras. Pode ser interessante, por exemplo, realizar uma calibração mais precisa do patamar T ou mesmo estudar novas características para representar os pixels de fundo e ovo. Além disso, podem ser empregadas outras estratégias de aprendizagem de máquina, bem como a combinação de várias abordagens distintas.

Quando comparada às técnicas presentes na literatura, a estratégia proposta alcançou taxas de acerto um pouco inferiores, evidenciando a necessidade de refinamento. No trabalho de [18], por exemplo, foram alcançados erros na estimação do número de ovos na faixa de 7% a 12% (de acordo com a técnica proposta). Já [19] obtiveram valores mais precisos, com erros no intervalo de 7% a 10%. Os erros obtidos por [11] estiveram na faixa de 7% a 12%. Já [9] obteve valores mais dispersos, onde os erros observados variaram entre 7% e 33%.

Além dos trabalhos citados, [20] pôde obter uma taxa de erros de 26,47% e [13] erros de 14% e 9,7%. Já [21] alcançou erro de 18,9% enquanto [22] obteve uma taxa de erro de apenas 3,5%. As estratégias propostas por [23] apresentaram erros de 15,38% e 27,43%.

De forma geral, os desempenhos apresentados nos trabalhos dependem diretamente da estratégia de contagem automática proposta e de características das imagens, tais como a resolução, contraste entre objetos de interesse e fundo, presença de artefatos indesejados, iluminação, entre outros aspectos.

AGRADECIMENTOS

Ao MEC-SESU, pelo financiamento deste projeto de iniciação científica a partir do Programa de Educação Tutorial (PET).

REFERÊNCIAS

- [1] A. F. Ribeiro, G. R. A. M. Marques, J. C. Voltolini, and M. L. F. Condino, "Associação entre incidência de dengue e variáveis climáticas," *Revista de Saúde Pública*, vol. 40, no. 4, pp. 671–676, Agosto 2006. [Online]. Available: <https://doi.org/10.1590/S0034-89102006000500017>
- [2] S. Mukherji and S. Kaushik, "Dengue: A runaway epidemic and a bewildered public health worker," *Medical Journal Armed Forces India*, vol. 71, no. 1, pp. 3 – 4, 2015. [Online]. Available: <https://doi.org/10.1016/j.mjafi.2014.12.002>
- [3] WHO, "Dengue and severe dengue," World Health Organization, 2022. [Online]. Available: <https://www.who.int/en/news-room/fact-sheets/detail/dengue-and-severe-dengue>
- [4] PAHO. (2022) Dengue y dengue grave - casos y muertes. Pan American Health Organization. [Online]. Available: <http://tinyurl.com/yckurfdv>

- [5] C. B. Rizzi, R. L. Rizzi, P. V. Pramiu, E. Hoffmann, and C. T. Codeço, "Considerações sobre a dengue e variáveis de importância à infestação por *Aedes aegypti*," *Revista Brasileira de Geografia Médica e da Saúde*, vol. 13, no. 24, pp. 24–40, Junho 2017, disponível em <https://seer.ufu.br/index.php/hygeia/article/view/35133>.
- [6] A. Brasil. (2017) Vacina dengue: esclarecimentos. <https://tinyurl.com/wwwlotohttps://tinyurl.com/wwwloto>.
- [7] P. S. C. Garcia, R. Martins, G. L. Lins Machado Coelho, and G. Câmara-Chávez, "Acquisition of digital images and identification of *Aedes aegypti* mosquito eggs using classification and deep learning," in *2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, Oct 2019, pp. 47–53, <https://doi.org/10.1109/SIBGRAPI.2019.00015>.
- [8] C. E. Silva and J. E. Limongi, "Avaliação comparativa da eficiência de armadilhas para a captura e coleta de *Aedes aegypti* em condições de campo," *Cadernos Saúde Coletiva*, vol. 26, pp. 241 – 248, 07 2018, <https://doi.org/10.1590/1414-462x201800030045>.
- [9] N. M. Portela, "Contagem automática de ovos de *Aedes aegypti* em imagens de ovitrampas," Mestrado em Engenharia da Computação, Escola Politécnica de Pernambuco da Universidade de Pernambuco, Recife, Brasil, 2009, <http://hdl.handle.net/10438/16722>.
- [10] N. M. Portela, C. A. B. Mello, W. P. dos Santos, A. L. B. Candeias, C. M. G. Gusmão, S. C. S. Machado, and M. A. B. Rodrigues, "A new algorithm for segmenting and counting *Aedes aegypti* eggs in ovitraps," in *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Sep. 2009, pp. 6714–6717, <https://doi.org/10.1109/IEMBS.2009.5333759>.
- [11] C. A. B. Mello, W. P. dos Santos, M. A. B. Rodrigues, A. L. B. Candeias, C. M. G. Gusmao, and N. M. Portela, "Automatic counting of *Aedes aegypti* eggs in images of ovitraps," in *Recent Advances in Biomedical Engineering*, G. R. Naik, Ed. Rijeka: IntechOpen, 10 2009, ch. 11, pp. 211–222, <https://doi.org/10.5772/7481>.
- [12] L. Brasil, M. Gomes, C. Miosso, M. Silva, and G. Amvame-Nze, "Web platform using digital image processing and geographic information system tools: A brazilian case study on dengue," *Biomedical engineering online*, vol. 14, p. 69, 07 2015, <https://doi.org/10.1186/s12938-015-0052-2>.
- [13] A. K. O. Tiba, A. F. R. Araujo, H. F. Bassani, and T. I. Ren, "Sistema autônomo de reconhecimento e contagem de ovos de *Aedes aegypti*," in *Anais do 10 Congresso Brasileiro de Inteligência Computacional*, G. d. A. Barreto and J. A. F. Costa, Eds. Fortaleza, CE: SBIC, 2011, pp. 1–8, <https://doi.org/10.21528/CBIC2011-27.4https://doi.org/10.21528/CBIC2011-27.4>.
- [14] J. Kittler, "Combining classifiers: A theoretical framework," *Pattern Analysis and Applications*, vol. 1, no. 1, pp. 18–27, 1998, disponível em <https://link.springer.com/article/10.1007/BF01238023>.
- [15] V. Gunes, M. Ménard, P. Loonis, and S. Petit-Renaud, "Combination, cooperation and selection of classifiers: A state of the art," *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 17, no. 08, pp. 1303–1324, 2003, disponível em <https://doi.org/10.1142/S0218001403002897>.
- [16] L. Kuncheva, *Combining Pattern Classifiers: Methods and Algorithms*. Wiley, 2014. [Online]. Available: <https://books.google.com.br/books?id=RtRLBAAQBAJ>
- [17] R. C. Prati, G. E. d. A. P. A. Batista, and M. C. Monard, "Curvas roc para avaliação de classificadores," *IEEE Latin America Transactions*, vol. 6, no. 2, pp. 215–222, 2008.
- [18] C. A. B. Mello, W. P. dos Santos, M. A. B. Rodrigues, A. L. B. Candeias, and C. M. G. Gusmao, "Image segmentation of ovitraps for automatic counting of *Aedes aegypti* eggs," in *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Aug 2008, pp. 3103–3106. [Online]. Available: <https://doi.org/10.1109/IEMBS.2008.4649860>
- [19] W. P. Santos, C. A. B. Mello, R. G. Mesquita, M. A. B. Rodrigues, A. L. B. Candeias, and C. M. G. Gusmão, "Um algoritmo para contagem automática de ovos do mosquito *Aedes aegypti* em ovitrampas para controle da dengue," in *XXI Congresso Brasileiro de Engenharia Biomédica*, 01 2008, pp. 1507–1510. [Online]. Available: <https://tinyurl.com/y88984bd>
- [20] M. G. N. M. Silva, M. A. B. Rodrigues, and R. E. Araujo, "Um novo método de segmentação e contagem de ovos do *Aedes aegypti* em ovitrampas," in *Anais do XXII Congresso Brasileiro de Engenharia Biomédica (CBEB)*, 01 2010, pp. 861–865. [Online]. Available: <http://www.sbeb.org.br/site/wp-content/uploads/XXIICBEB2010Vol2.pdf>
- [21] L. d. N. Feitosa, "Sistema de contagem automática de ovos do *Aedes aegypti* a partir de processamento de imagens das palhetas de ovitrampas," Graduação em Análise e Desenvolvimento de Sistemas, Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte, Pau dos Ferros, Brasil, 2015. [Online]. Available: <https://tinyurl.com/y4yu3whp>
- [22] H. S. Morais, O. S. Santos, M. A. Rocha, T. C. S. Almeida, L. M. Brasil, G. D. Amvame-Nze, C. J. Miosso, M. V. C. Costa, and G. A. Pizo, "Monitoring information system of *Aedes aegypti* reproduction," in *World Congress on Medical Physics and Biomedical Engineering, June 7-12, 2015, Toronto, Canada*, D. A. Jaffray, Ed. Cham: Springer International Publishing, 2015, pp. 1423–1426. [Online]. Available: https://doi.org/10.1007/978-3-319-19387-8_347
- [23] L. D. Alves, "Desenvolvimento de um sistema de baixo custo para contagem automática de ovos de *Aedes aegypti* usando técnicas de processamento de imagens," Mestrado em Modelagem Matemática da Informação, Escola de Matemática Aplicada da Fundação Getúlio Vargas, Rio de Janeiro, Brasil, 2016. [Online]. Available: <http://hdl.handle.net/10438/16722>