

Quantificação de mosquitos *Aedes aegypti* a partir de imagens de smartphones

João Pedro Ortega¹, Barbara Lepretti de Nadai¹, André Gustavo Maletzke¹

¹Universidade Estadual do Oeste do Paraná (UNIOESTE)
Centro de Engenharias e Ciências Exatas – Foz do Iguaçu – PR – Brasil

{joao.ortega1, barbara.nadai, andre.maletzke}@unioeste.br

Abstract. *Automatic surveillance of the Aedes aegypti mosquito is a technological development with the potential to transform current monitoring practices. Monitoring disease vector mosquitoes means estimating the mosquito population, i.e., counting the number of mosquitoes from the target species in a specific region. Counting is the most fundamental concept in mathematics and a challenge for Machine Learning. Quantification is a recently formalized Machine Learning task aiming to predict the distribution of classes from a test set. In this paper, different quantifiers were evaluated using images of disease vectors. The empirical results demonstrate that the classify and count method is a baseline, being outperformed by DyS and HDy methods.*

Resumo. *A vigilância automática do mosquito Aedes aegypti é um desenvolvimento tecnológico com potencial de transformar as atuais práticas de monitoramento. Monitorar mosquitos se traduz em estimar o tamanho da população de mosquitos, isto é, contar a quantidade de mosquitos da espécie alvo dada a região monitorada. Contar é o conceito mais fundamental da matemática e um desafio para o Aprendizado de Máquina. Nesse sentido, a quantificação é uma tarefa de Aprendizado de Máquina recentemente formalizada, cujo objetivo é prever a distribuição de classes dado um conjunto de teste. Neste trabalho, foram avaliados diferentes quantificadores a partir de imagens de vetores de doenças. Os resultados empíricos demonstram que o método de classificar e contar é um baseline, sendo superado pelos métodos DyS e HDy.*

1. Introdução

Doenças transmitidas por mosquitos têm sido negligenciadas nos últimos anos, embora afetem a vida de milhões de pessoas ao longo do globo. Um estudo recente revela que há cerca de 390 milhões de infecções de dengue por ano, dentre estas apenas 96 milhões de casos se manifestam clinicamente [Bhatt et al. 2013]. No Brasil essa situação não é diferente, há casos de dengue, Zika e Chikungunya em todo o país, sendo estas as arboviroses que mais impactam na saúde pública. Em 2019 foi registrado 1.439.471 casos de dengue no país, um aumento de 599,5% com relação ao ano anterior [Ministério da Saúde 2019].

A vigilância de mosquitos é crucial para entender a ecologia e a evolução de uma espécie de vetor e para otimizar o gasto de recursos escassos ao planejar intervenções [Reed et al. 2019]. Atualmente a estratégia preconizada pelo Ministério de Saúde é denominada de Levantamento de Índice Rápido para o *Aedes aegypti* (LI-RAa) [Ministério da Saúde 2013]. Essa estratégia consiste na estratificação geográfica da

área de interesse, comumente referente a um município, seguida do sorteio dos imóveis para a realização de vistorias em busca de focos do mosquito *Ae. aegypti*. Embora a abordagem mais utilizada seja a busca por larvas, existem mecanismos que se concentram na captura de mosquitos adultos. Para isso, são utilizados diferentes tipos de armadilhas para atrair e capturar as fêmeas que estão em busca, por exemplo, de um local para ovipositar [Pezzin et al. 2016]. Porém, esta solução ainda depende de um profissional da área, um entomólogo, para a realização da classificação e contagem das espécies capturadas, sendo assim uma tarefa manual e lenta, podendo levar a resultados imprecisos. Imagine uma solução que automatize a contagem de vetores, não dependendo de profissionais especializados. Esse recurso poderia resultar em um avanço significativo no processo de tomada de decisão sobre como e quando intervir em cada área monitorada.

Dado esse panorama, a área de Aprendizado de Máquina pode auxiliar mediante as tarefas de classificação e quantificação. A classificação tem por objetivo determinar a classe (espécie) de um objeto (mosquito), dados seus atributos [Flach 2012]. Já a quantificação tem por objetivo analisar o comportamento de grupos, ou seja, prever a distribuição de cada classe dado certo conjunto de dados (CD) [Forman 2006]. O resultado da quantificação é a informação necessária para direcionar ações de combate e controle de mosquitos vetores.

Embora a quantificação e a classificação sejam tarefas diferentes, a quantificação utiliza frequentemente a classificação como etapa intermediária. Por exemplo, o quantificador Classificar e Contar (CC) consiste em classificar cada objeto de entrada e então contar quantas instâncias pertencem a determinada classe. Porém, o CC contém deficiências evidentes, como o erro sistêmico introduzido quando há mudanças na distribuição das classes [Dietterich and Kong 1995]. Esta é uma diferença importante entre a classificação e quantificação, em problemas de contagem a distribuição das classes não é estacionária, caso contrário seria possível estimar a distribuição de classes no conjunto de teste baseado nos dados de treino.

Dispor de uma gama de recursos tecnológicos que possam auxiliar no controle do vetor *Ae. aegypti* é uma estratégia que não pode ser ignorada. Considerando a popularidade e a qualidade dos recursos de hardware presentes nos dispositivos móveis (*smartphones*) atuais, este trabalho tem como objetivo avaliar diferentes quantificadores aplicados à contagem de mosquitos da espécie *Ae. aegypti* a partir de imagens de *smartphones*.

Este trabalho está organizado da seguinte maneira: na Seção 2 são apresentados os materiais e método para o desenvolvimento deste trabalho. Nas Seções 3 e 4 são apresentados os resultados e a discussão, respectivamente; e na Seção 5 são apresentadas as conclusões e trabalhos futuros.

2. Material e Método

O desenvolvimento deste trabalho foi estruturado nas seguintes etapas: (i) construção de conjunto de imagens, (ii) construção de classificadores, (iii) construção de quantificadores e (iv) avaliação experimental. Cada uma das etapas são apresentadas a seguir.

2.1. Etapa 1 - Construção de conjunto de imagens

O objetivo desta etapa consiste em coletar imagens de diversas espécies de mosquito. Foram coletadas imagens de mosquitos criados no Laboratório de Entomologia Compu-

tacional (COEN) da UNIOESTE e de conjuntos de imagens presentes na literatura.

A coleta de imagens realizada em laboratório com uso de dois *smartphones* distintos: iPhone 7 e Motorola Moto X2. Foram utilizados, em conjunto dos *smartphones*, dois dispositivos auxiliares de amplificação: **Lente**: Universal Clip Type LED Cellphone Microscope, Aumento: 60x, Lens Diameter: 11mm (lente); e **Lupa**: Estereomicroscópio tipo lupa modelo EL224 (2x e 4x (embutidas) / Amplificação: 20x e 40x).

A captura das imagens foi realizada de maneira individualizada para cada mosquito. Cada mosquito foi posicionado sobre um fundo de cor azul, padronizando o processo de captura. Foram coletadas imagens das seguintes espécies de mosquito em ambos os sexos: *Ae. aegypti*, *Ae. albopictus*, *Anopheles aquasalis* e *Culex quinquefasciatus*.

Na Figura 1 é apresentada uma representação esquemática do processo de coleta, o qual é composto quatro fases: (1) classificação e separação manual em containers de cada espécime por espécie e sexo; (2) escolha de um *smartphone* para realizar a captura da imagem; (3) uso de dispositivo auxiliar para amplificação da imagem; e (4) *upload* da imagem para a base de dados.




Figura 1. Processo de coleta de dados.

Após a coleta ser concluída, as imagens foram estruturadas conforme gênero, espécie, sexo, identificação do *container*, *smartphone*, dispositivo de amplificação e a amplificação utilizada na captura da imagem. A partir da coleta de dados e de conjuntos de dados presentes na literatura foram obtidos os seguintes CDs (em parênteses a distribuição de classes):

- **CD COEN**: imagens coletadas em laboratório, totalizando 2258 imagens. Contém quatro espécies de mosquitos (machos e fêmeas), *Ae. aegypti* (17%), *Ae. albopictus* (28%), *An. aquasalis* (27%) e *Cx. quinquefasciatus* (28%);
- **CD Park**: imagens coletadas de [Park et al. 2020], total de 3578 imagens. Dividido em seis classes, *Ae. albopictus* (17%), *Ae. vexans* (16%), *An. sinensis* (16%), *Cx. pipiens* (17%), *Cx. tritaeniorhynchus* (17%) e não vetores de doenças (17%), composta por *Ae. dorsalis*, *Ae. koreicus* e *Cx. inatomii*;
- **CD Pise**: imagens coletadas de [Pise et al. 2022], total de 2640 imagens. Contém três espécies de mosquitos, *Ae. aegypti* (34%), *An. stephensi* (21%) e *Cx. quinquefasciatus* (45%).

Os conjuntos de dados CD Park e CD Pise passaram por processo de *augmentation* por parte dos autores, visando aumentar o tamanho de cada CD. A partir dos conjuntos de dados coletados, foram criados seis conjuntos de dados binários com ênfase na contagem de imagens do mosquito transmissor da dengue, Zika e Chikungunya (em parênteses a distribuição de classes):

- ***Aedes* × ¬*Aedes* (CD1):** obtido do CD COEN, totalizando 1435 imagens e composto pelas classes *Aedes* e ¬*Aedes*, doravante denominadas de classes positiva (\oplus) e negativa (\ominus), respectivamente. A classe \oplus , representa 45% do CD e é composta pelas espécies *Ae. aegypti* e *Ae. albopictus*. A classe \ominus pelas espécies *An. aquasalis* e *Cx. quinquefasciatus* e representa 55% do CD;
- ***Aedes* Fêmea × ¬*Aedes* Fêmea (CD2):** obtido do CD COEN e composto por 763 imagens. A classe *Aedes* Fêmea representa a classe \oplus e é composta pelas espécies *Ae. aegypti* e *Ae. albopictus* fêmea, representando 46% do CD. A classe ¬*Aedes* Fêmea representa a classe \ominus com 54% do CD e contém imagens das espécies *An. aquasalis* e *Cx. quinquefasciatus* fêmea;
- ***Ae. aegypti* × ¬*Ae. aegypti* (CD3):** contém 1029 imagens extraídas do CD COEN. A classe *Ae. aegypti* representa a classe \oplus com 22% deste CD e a classe ¬*Ae. aegypti* a classe \ominus com 78% do CD e sendo constituída por imagens das espécies *Ae. albopictus*, *An. aquasalis* e *Cx. quinquefasciatus*;
- ***Aedes* × ¬*Aedes* (CD4):** obtido do conjunto de imagens disponibilizado por [Park et al. 2020], totalizando 2978 imagens. As espécies *Ae. Albopictus* e *Ae. vexans* foram agrupadas para formar a classe \oplus , representando 40% das imagens. O restante, 60% das imagens, foram agrupadas para gerar a classe \ominus , composta pelas espécies *An. sinensis*, *Cx. pipiens*, *Cx. tritaeniorhynchus*, *Ae. dorsalis*, *Ae. koreicus* e *Cx. inatomii*;
- **Vetor × ¬Vetor (CD5):** extraído do CD disponibilizado por [Park et al. 2020], totalizando 3578 imagens. A classe Vetor representa a classe \oplus com 83% do CD e é composta pelas espécies *Ae. albopictus*, *Ae. vexans*, *An. sinensis*, *Cx. pipiens* e *Cx. tritaeniorhynchus*. A classe ¬Vetor representa a classe \ominus com 17% do CD e é composta pelas espécies *Ae. dorsalis*, *Ae. koreicus* e *Cx. inatomii*;
- ***Ae. aegypti* × ¬*Ae. aegypti* (CD6):** obtido das imagens disponibilizadas em [Pise et al. 2022], composto por 2640 imagens. A classe *Ae. aegypti* representa a classe \oplus com 34% das imagens e é composta pela espécie *Ae. aegypti*. Já a classe ¬*Ae. aegypti* representa a classe \ominus e contém 66% das imagens constituídas pelas espécies *An. stephensi* e *Cx. quinquefasciatus*.

2.2. Etapa 2 - Construção de classificadores

Nesta etapa é realizada a construção de classificadores capazes de identificar, por exemplo, espécies de mosquitos com base nas imagens coletadas na etapa anterior. A classificação é uma tarefa na área de Aprendizado de Máquina que consiste em induzir um modelo preditivo h usando um conjunto de treino $D = \{(x_1, y_1), \dots, (x_n, y_n)\}$, onde $x_i \in \mathcal{X}$ é um vetor com m atributos em um espaço m -dimensional de \mathcal{X} , e $y_i \in Y = \{c_1, \dots, c_l\}$ é a respectiva classe. O objetivo da classificação é prever corretamente as classes de cada instância do conjunto de teste, com base nos valores de dos atributos. Portanto, um classificador é um modelo h induzido a partir de D , de tal modo que $h : \mathcal{X} \rightarrow \{c_1, \dots, c_l\}$ [Hassan et al. 2020].

Entretanto, os métodos tradicionais de Aprendizado de Máquina requerem que os dados estejam representados de forma estruturada, como no formato atributo-valor. Dessa forma, para os conjuntos de dados construídos na etapa anterior possam ser utilizados é necessário que sejam convertidos ou que técnicas específicas para construção de classificadores sejam aplicadas.

Portanto nesta etapa foram utilizadas técnicas específicas, como as baseadas em Aprendizado Profundo, um exemplo são as Redes Neurais Convolucionais (CNNs) [Guo et al. 2016], as CNNs têm sido amplamente aplicadas na análise de imagens. Consistem em uma composição de módulos simples, mas não lineares, onde a partir do dado bruto são construídas representações (transformações) em diversos níveis de abstração. Assim, a partir destas transformações é possível aprender funções complexas e não depender inteiramente de recursos criados explicitamente. Para a construção de classificadores a partir das imagens coletadas foram utilizados dois modelos de CNNs amplamente conhecidos na literatura:

- Very Deep Convolutional Network (VGG16): proposto por [Simonyan and Zisserman 2014], aceita como entrada uma imagem de tamanho 224 por 224 pixels, possui um total de 21 camadas, 13 camadas de convolução, 5 camadas de *Max Pooling* e 3 camadas densas;
- Deep Residual Network Architectures (ResNet50): proposto por [He et al. 2016], aceita como entrada uma imagem de tamanho de 224 por 224 pixels, possui 48 camadas de convolução, 1 camada de *Max Pooling* e 1 camada de *Average Pooling*, resultando em 50 camadas no total.

2.3. Etapa 3 - Construção de quantificadores

Nesta etapa foram construídos métodos de quantificação com o intuito de realizar a contagem de mosquitos de espécies diferentes. [Forman 2006] observou que em diversas aplicações envolvendo classificação o objetivo final não era rotular instâncias de dados individuais, mas estimar a distribuição (frequência relativa) dessas classes dado um conjunto de testes. A partir dessa observação cunhou-se uma nova tarefa em Aprendizado de Máquina, denominada de quantificação.

A quantificação utiliza frequentemente a classificação como etapa intermediária. Classificadores empregam diferentes mecanismos para decidir qual classe será atribuída a qualquer observação. Na classificação binária, uma das duas classes é denominada *classe positiva* ($c_1 = \oplus$), enquanto que a outra é denominada *classe negativa* ($c_2 = \ominus$). Logo, um **scorer** é um modelo induzido a partir de D tal que $s : \mathcal{X} \rightarrow R$.

Um *scorer* produz um valor numérico para cada instância de teste correlacionado com a probabilidade da instância pertencer a uma determinada classe. Na classificação, se o *score* for superior a um determinado limite a instância é classificada como positiva ou negativa, caso contrário [Flach 2012]. No entanto, diferentemente de um classificador, um quantificador prediz a partir de um conjunto de testes a quantidade de instâncias pertencentes a cada classe. Um **quantificador** é um modelo induzido a partir de D que prevê a prevalência de cada classe em uma amostra, tal que $q : S^{\mathcal{X}} \rightarrow [0, 1]^l$, onde $S^{\mathcal{X}}$ denota o universo de amostras de \mathcal{X} . Para uma determinada amostra de teste $S \in S^{\mathcal{X}}$, o quantificador gera um vetor $\hat{\mathbf{p}} = [\hat{p}_1, \dots, \hat{p}_l]$, onde \hat{p}_i estima a probabilidade anterior para a classe c_i , tal que $\sum_{j=1}^l \hat{p}_j = 1$. O objetivo é $[\hat{p}_1, \dots, \hat{p}_l]$ estar o mais próximo possível das verdadeiras probabilidades reais $[P(c_1), \dots, P(c_l)]$ da distribuição de probabilidade da qual S foi amostrado.

Na quantificação o *score* é um parâmetro de entrada para diversos métodos. A partir dos *scores* é possível calcular diversas taxas como as de verdadeiros positivos (*tpr*),

falsos positivos (*fpr*) e de falsos negativos (*fnr*) para diferentes limiares. Essas métricas atuam como fatores corretivos em alguns métodos de quantificação.

Diversos métodos de quantificação foram propostos nos últimos anos. [González et al. 2017] propôs uma taxonomia para agrupar diferentes quantificadores de acordo com suas características da seguinte maneira:

- I. **Classificar, Contar e Corrigir:** métodos que inicialmente classificam cada instância e após é realizada a contagem dos exemplos de cada classe. Também envolvem métodos que aplicam correção sobre resultado da contagem;
- II. **Adaptação de algoritmos de classificação:** são métodos construídos a partir de modificações em algoritmos de classificação visando obter melhores quantificadores ao invés de classificadores;
- III. **Correspondência de distribuição:** nesta abordagem a ideia de classificar e contar não é utilizada. Os métodos buscam modificar a distribuição de classes na etapa de treino para corresponder a distribuição encontrada no teste.

Neste trabalho são utilizados quantificadores do Grupo I e III. Na Tabela 1 são representados os métodos de quantificação implementados neste trabalho, agrupados conforme a taxonomia proposta por [González et al. 2017].

Tabela 1. Quantificadores por taxonomia.

Grupo	Quantificador	Descrição	Referência
I	CC	Classifica e Conta	[Forman 2006]
	ACC	Classifica e Conta Ajustado	
	X	Classificador com limiar de decisão onde $fnr = fpr$	
	MAX	Classificador com limiar de decisão onde $tpr - fpr$ é máximo	
	T50	Classificador com limiar de decisão onde $tpr = 50\%$	
	MS	<i>Median Sweep</i>	
III	HDy	Modelo de mistura de com distância <i>Hellinger</i>	[González-Castro et al. 2013]
	DyS	Modelo de mistura da família DyS com distância <i>Topsoe</i>	[Maletzke et al. 2019]
	SORD	Método <i>Sample-ORD</i>	[Maletzke et al. 2019]

2.4. Etapa 4 - Avaliação experimental

Foram realizados experimentos a fim de avaliar a performance de quantificadores ao problema de contagem de espécies de mosquitos. Para isso, foram utilizadas as CNNs VGG16 e ResNet50. Ambas nas configurações de pesos pré-treinados¹ (PT) e não pré-treinados (NPT). Para ambas as CNNs foi utilizada uma taxa de aprendizado de $1e - 5$.

Os conjuntos de dados foram particionados igualmente em treino e teste. Após, o conjunto de treino foi particionado novamente igualmente em treino e validação. Foram utilizadas 100 épocas para treinar cada CNN e realizar a validação. Durante a validação foram estimados os *scores* de ambas as classes (\oplus e \ominus), bem como as taxas *tpr* e *fpr*. Os *scores* e as taxas são utilizados como parâmetro de entrada para diversos quantificadores. Esse processo foi repetido duas vezes, invertendo as partições de treino e validação.

O conjunto de teste é destinado para avaliação dos quantificadores. A partir do conjunto de teste foram extraídas diversas amostras, com variações no tamanho da amostra (10, 20, 30, 40, 50 e 100) e a proporção da classe positiva, variando de 0% a 100%

¹Conjunto de parâmetros treinados previamente em um grande CD. Camadas convolucionais da CNN utilizam características e padrões encontrados neste CD prévio para futuras predições.

com incrementos de 5%. Para cada combinação de tamanho de amostra e variação na distribuição da classe positiva foram geradas dez réplicas.

Para a avaliação dos quantificadores foi utilizado o Erro Médio Absoluto (MAE). A avaliação experimental tem o objetivo responder as seguintes questões de pesquisa: **(Q1)** qual é a melhor configuração do parâmetro de peso (PT e NPT) das CNNs para cada um dos quantificadores em cada CD? **(Q2)** qual o melhor quantificador independentemente do modelo de CNN para cada CD? e **(Q3)** qual o melhor quantificador para o problema de quantificação de imagens de mosquitos vetores de doenças?

Para a comparação dos resultados foi utilizado o teste estatístico t-student para comparações entre quantificadores para um mesmo CD e o teste de Friedman com pós-teste Nemenyi para comparações entre quantificadores e todos os CDs. Para ambos os testes estatísticos foi considerado nível de significância de 95%. Códigos e CDs para reproduzir os experimentos realizados neste trabalho estão disponíveis no repositório Git²

3. Resultados

Para responder a primeira questão da avaliação experimental **(Q1)**, são apresentadas as Tabelas 2 e 3. Na Tabela 2 é apresentado o MAE dos quantificadores para cada CD, utilizando como *scorer* o ResNet50 em ambas as configurações de pesos, PT e NPT. Já na Tabela 3 são apresentados os resultados utilizando como *scorer* o VGG16. Valores em negrito indicam menor MAE. Após, foi realizada a avaliação estatística mediante o teste t-student para comparar os valores de MAE por cada configuração (PT e NPT) para cada quantificador em cada CD de forma separada. Valores sublinhados em ambas as tabelas indicam que há diferença estatisticamente significativa entre as configurações avaliadas.

Tabela 2. MAE dos quantificadores utilizando como *scorer* o ResNet50.

CDs	CC	ACC	X	MAX	T50	MS	DyS	HDy	SORD
CD1 NPT	<u>0,147</u>	0,347	0,269	0,285	0,382	0,384	0,330	0,292	0,343
CD1 PT	0,328	0,344	0,343	0,300	0,430	0,332	0,341	0,364	0,295
CD2 NPT	0,094	0,182	0,193	0,193	0,235	0,215	0,232	0,243	0,203
CD2 PT	0,159	0,206	0,282	0,327	0,494	0,206	0,378	0,386	0,298
CD3 NPT	0,103	0,260	0,151	0,106	0,251	0,312	0,087	0,161	0,234
CD3 PT	0,494	0,494	0,208	0,240	0,407	0,494	0,195	0,195	0,207
CD4 NPT	0,481	0,506	0,506	0,506	0,506	0,506	0,505	0,504	0,506
CD4 PT	0,361	0,187	0,455	0,455	0,435	0,199	0,352	0,417	0,426
CD5 NPT	0,294	0,294	0,305	0,305	0,476	0,284	0,291	0,157	0,283
CD5 PT	0,361	0,187	0,455	0,455	0,435	0,199	0,352	0,417	0,426
CD6 NPT	0,490	0,494	0,277	0,268	0,327	0,335	0,467	0,404	0,490
CD6 PT	0,463	<u>0,294</u>	0,245	0,245	0,283	0,359	0,206	0,219	0,213

Para responder a questão **Q2** da avaliação experimental foram selecionados os melhores resultados para cada um dos quantificadores independentemente de *scorer*, isto é, ResNet50 e VGG16, e da configuração de pesos (PT e NPT). O resultado dessa seleção é apresentado na Tabela 4. Valores em negrito apontam o menor MAE encontrado por um quantificador em um CD. Valores sublinhados indicam que há diferença estatística entre os quantificadores em um CD.

Na Tabela 4 nota-se que para o CD1, CD3 e CD6, o quantificador DyS apresentou o menor MAE, enquanto que para CD2, CD3 e CD4 o CC obteve MAE menor.

²<https://github.com/JPortegaa/MosquitoQuantificationCNN>.

Tabela 3. MAE dos quantificadores utilizando como *scorer* o VGG16.

CDs	CC	ACC	X	MAX	T50	MS	DyS	HDy	SORD
CD1 NPT	0,406	0,411	0,375	0,325	0,382	0,410	0,398	0,410	0,402
CD1 PT	0,046	0,041	0,040	0,048	0,114	0,038	0,031	0,038	0,038
CD2 NPT	0,182	0,116	0,178	0,139	0,116	0,105	0,108	0,104	0,113
CD2 PT	0,125	0,123	0,119	0,126	0,121	0,135	0,185	0,227	0,133
CD3 NPT	0,494	0,494	0,506	0,208	0,506	0,494	0,395	0,233	0,207
CD3 PT	0,394	0,502	0,506	0,506	0,499	0,506	0,500	0,489	0,506
CD4 NPT	0,494	0,494	0,506	0,494	0,506	0,494	0,506	0,354	0,494
CD4 PT	0,143	0,213	0,187	0,186	0,224	0,203	0,186	0,176	0,198
CD5 NPT	0,506	0,506	0,506	0,506	0,506	0,506	0,506	0,503	0,506
CD5 PT	0,143	0,213	0,187	0,186	0,224	0,203	0,186	0,176	0,198
CD6 NPT	0,494	0,494	0,443	0,503	0,443	0,494	0,475	0,460	0,473
CD6 PT	0,336	0,395	0,395	0,382	0,419	0,385	0,396	0,418	0,374

Tabela 4. Menor MAE para cada quantificador independentemente do *scorer*.

CDs	CC	ACC	X	MAX	T50	MS	DyS	HDy	SORD
CD1	0,046	0,041	0,040	0,048	0,114	0,038	0,031	0,038	0,038
CD2	0,094	0,116	0,119	0,126	0,116	0,105	0,108	0,104	0,113
CD3	0,103	0,260	0,151	0,106	0,251	0,312	0,087	0,161	0,207
CD4	0,143	0,187	0,187	0,186	0,224	0,199	0,186	0,176	0,198
CD5	0,143	0,187	0,187	0,186	0,224	0,199	0,186	0,157	0,198
CD6	0,336	0,294	0,245	0,245	0,283	0,335	0,206	0,219	0,213

Para responder a questão **Q3** foi utilizado o Friedman com pós-teste Nemenyi sobre os MAEs dos quantificadores presentes na Tabela 4. Como resultado é apresentado o diagrama de diferença crítica entre os quantificadores na Figura 2. Os quantificadores estão dispostos por linhas com base no *ranking* em função do MAE. Os quantificadores conectados pela linha horizontal indicam que não há diferença estatística significativa entre os erros dos quantificadores.




Figura 2. Diagrama de diferença crítica entre quantificadores.

4. Discussão

A avaliação experimental possibilitou responder a três questões de pesquisa. A **Q1**, visando avaliar a influência da aplicação de *transfer learning* em modelos de CNN atuando como *scorers* como parte do processo de quantificação. Para isso, os dois modelos de CNN foram avaliados com pesos pré-treinados (PT) e não pré-treinados (NPT), separadamente. Para ResNet50 a influência de *transfer learning*, isto é, configuração PT, não foi significativa, produzindo quantificadores com menor MAE em 52% das vezes (Tabela 2). Entretanto, para o VGG16 o uso de *transfer learning* foi significativo produzindo quantificadores com menor MAE em 76% dos casos (Tabela 3). Embora, a comparação entre ResNet50 e VGG16 não tenha sido abordada neste trabalho, observou-se que os

resultados produzidos pelo VGG16, em média, são superiores ao do ResNet50. Este resultado é relevante, considerando que em problemas de quantificação é possível obter um quantificador perfeito usando como base um *scorer* não perfeito [Forman 2006].

A seguinte questão pesquisa (**Q2**) buscou avaliar os resultados independentemente da necessidade de escolha do modelo de CNN. Para isso, foi apresentada a Tabela 4 contendo o menor MAE para cada quantificador, independentemente de qual modelo os produziu (ResNet50 ou VGG16), com e sem *transfer learning* (PT e NPT). Os resultados indicaram o CC e o DyS como melhores estratégias de quantificação. Ambos os métodos apresentaram melhores resultados em três CD. Entretanto o DyS obteve melhor MAE com diferença estatisticamente significativa em dois CD contra somente um CD do CC. De acordo com [Maletzke et al. 2019] o DyS tem sua performance degradada significativamente em amostras pequenas, inferiores a 20 instâncias (imagens). Neste trabalho, optou-se por manter amostras pequenas em virtude da rotina de monitoramento de mosquitos vetores obter diversidade na quantidade de capturas. Por restrições de espaço, neste trabalho, não foi incluída a avaliação sobre tamanho de amostra.

A última questão de pesquisa (**Q3**) é um complemento da questão **Q2** e teve como objetivo identificar o melhor quantificador para o problema. Na Figura 2 é apresentado o gráfico de diferença crítica, no qual o DyS e o HDy são os dois métodos com melhor *ranking* médio, seguidos por CC, SORD, X, MAX, MS, ACC e T50. Embora, não tenha sido observada diferença estatisticamente significativa entre os métodos com exceção do T50, os métodos baseados em modelo de mistura mostraram-se promissores para este problema em relação aos demais.

É importante observar que os conjuntos de dados CD1, CD2, CD3 e CD6 possuem maior aderência com o objetivo deste trabalho que é a contagem do mosquito *Ae. aegypti*. Para esses CDs, o CC apresentou melhor resultado em somente um deles (CD2) sem diferença estatisticamente significativa. Esse resultado, indica que possivelmente o CC não seja o melhor quantificador de mosquitos *Ae. aegypti* a partir de imagens utilizando como *scorer* os modelos de CNN avaliados.

5. Conclusões

Doenças transmitidas por mosquitos têm sido um problema de saúde pública em diversas regiões do mundo e, em especial, no Brasil. Dispor de tecnologias de fácil uso e que façam uso de recursos já existentes podem auxiliar na mitigação desse problema. Foram explorados métodos de quantificação para auxiliar na contagem do vetor *Ae. aegypti* mediante imagens de *smartphones*. A estratégia de classificar e contar, comumente utilizada, foi superada por outros métodos de quantificação. Esse resultado é importante para a construção futura de mecanismos de monitoramento a partir de imagens utilizando dispositivos móveis como *smartphones*. Trabalhos futuros incluem avaliar a influência do tamanho da amostra, outros quantificadores, bem como outros modelos de CNN.

Referências

Bhatt, S., Gething, P. W., Brady, O. J., Messina, J. P., Farlow, A. W., Moyes, C. L., Drake, J. M., Brownstein, J. S., Hoen, A. G., Sankoh, O., et al. (2013). The global distribution and burden of dengue. *Nature*, 496(7446):504–507.

- Dietterich, T. G. and Kong, E. B. (1995). Machine learning bias, statistical bias, and statistical variance of decision tree algorithms.
- Flach, P. (2012). *Machine learning: the art and science of algorithms that make sense of data*. Cambridge University Press.
- Forman, G. (2006). Quantifying trends accurately despite classifier error and class imbalance. In *Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 157–166.
- González, P., Castaño, A., Chawla, N. V., and Coz, J. J. D. (2017). A review on quantification learning. *ACM Computing Surveys (CSUR)*, 50(5):1–40.
- González-Castro, V., Alaiz-Rodríguez, R., and Alegre, E. (2013). Class distribution estimation based on the hellinger distance. *Information Sciences*, 218:146–164.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., and Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187:27–48.
- Hassan, W., Maletzke, A., and Batista, G. (2020). Accurately quantifying a billion instances per second. In *2020 IEEE 7th International Conference on Data Science and Advanced Analytics (DSAA)*, pages 1–10. IEEE.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778.
- Maletzke, A., dos Reis, D., Cherman, E., and Batista, G. (2019). Dys: A framework for mixture models in quantification. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 33, pages 4552–4560.
- Ministério da Saúde (2013). Levantamento rápido de índices para aedes aegypti–liraa para vigilância entomológica do aedes aegypti no brasil: metodologia para avaliação dos índices de breteau e predial e tipo de recipientes.
- Ministério da Saúde (2019). Boletim epidemiológico 22. Vol. 50, pp. 1-11.
- Park, J., Kim, D. I., Choi, B., Kang, W., and Kwon, H. W. (2020). Classification and morphological analysis of vector mosquitoes using deep convolutional neural networks. *Scientific reports*, 10(1):1012.
- Pezzin, A., Sy, V., Puggioli, A., Veronesi, R., Carrieri, M., Maccagnani, B., and Bellini, R. (2016). Comparative study on the effectiveness of different mosquito traps in arbovirus surveillance with a focus on wnv detection. *Acta tropica*, 153:93–100.
- Pise, R., Patil, K., Laad, M., and Pise, N. (2022). Dataset of vector mosquito images. *Data in Brief*, 45:108573.
- Reed, E. M., Byrd, B. D., Richards, S. L., Eckardt, M., Williams, C., and Reiskind, M. H. (2019). A statewide survey of container aedes mosquitoes (diptera: Culicidae) in north carolina, 2016: a multiagency surveillance response to zika using ovitraps. *Journal of medical entomology*, 56(2):483–490.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.