

Comparativo de algoritmos de machine learning para identificação de moscas da espécie *Drosophila suzukii* através de imagens das asas

Leila Maria Rodrigues de Sousa
Universidade Federal do Ceará
Sobral, Ceará - Brasil

Carlos Eduardo da Silva Brandão
Universidade Federal do Ceará
Sobral, Ceará - Brasil

Iális Cavalcante de Paula Júnior
Universidade Federal do Ceará
Sobral, Ceará - Brasil

Resumo—A *Drosophila suzukii* é capaz de atacar frutos em período de amadurecimento, geralmente, pequenos e de pele macia, como morango, pitanga, cereja, framboesa, ao contrário de outras espécies de moscas que atacam apenas frutos podres. A inserção de larvas, por meio das fêmeas, causa danos diretos e indiretos, comprometendo a qualidade das frutas e elevando custos de produção. A principal forma de identificação dos machos é através de manchas escuras presentes no topo das asas, já as fêmeas apresentam um ovopositor estreito que possibilita a introdução dos ovos dentro dos frutos. Por possuir tamanho pequeno, em média quatro milímetros, e asas visualmente semelhantes a de outras *Drosophilas*, a identificação das fêmeas torna-se uma tarefa difícil. Este trabalho propõe um método de discriminação de gênero da *Drosophila suzukii* e diferenciação da espécie em relação a outras moscas, a partir de características extraídas de imagens das asas. A abordagem é fundamentada na dimensão fractal extraída da segmentação por filtro de Canny das componentes da Transformada de Wavelet Estacionária. A metodologia foi validada com os métodos de validação cruzada K-Fold e Leave One Out e na utilização de seis classificadores distintos: K-Vizinhos Mais Próximos, Máquina de Vetor de Suporte, Análise por Discriminante Linear, Análise por Discriminante Quadrático, Árvore de Decisão e Floresta Aleatória. Os resultados obtidos foram satisfatórios, com taxas de acerto superiores a 90%, validando a metodologia sugerida em ambos os cenários considerados, demonstrando eficácia na resolução de problemas que possuam base de imagens de tamanho reduzido.

I. INTRODUÇÃO

A fruticultura nas últimas décadas tem sido um dos setores mais prejudicados com o surgimento de novas pragas, o que ocasiona aumento dos custos de produção e compromete a qualidade das frutas. Dentre essas pragas, as conhecidas moscas das frutas têm sido uma ameaça constante nas plantações [1]. A *Drosophila suzukii* é um exemplo de uma dessas espécies que causa danos significativos às culturas agrícolas.

A mosca possui tamanho pequeno, quando adulto o macho mede em média três milímetros e as fêmeas, quatro. Também conhecida como drosófila de asa manchada devido a presença de manchas escuras nas asas do macho observado na Figura 1(a), enquanto as fêmeas são reconhecidas pela presença de um ovopositor estreito, duplamente serrado, com uma série de dentes observado na Figura 1(b), que possibilitam a inserção dos ovos dentro dos frutos [2]. Diferentemente das outras moscas da espécie *Drosophila* que atacam somente frutos podres ou danificados, é capaz de causar danos em frutos no início

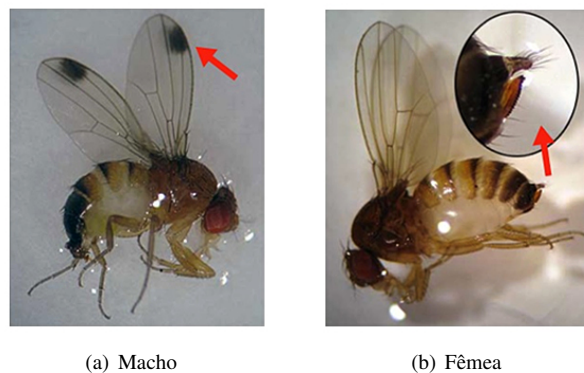


Figura 1. Comparativo entre macho e fêmea

do período de amadurecimento, devido a isso, provoca danos severos geralmente a frutos de pele macia e pequenos, como morango, cereja, mirtilo, amora-preta, framboesa e pitanga [3].

A identificação e diferenciação da *Drosophila suzukii* se torna relevante para contribuir em estudos posteriores que auxiliem na compreensão sobre a espécie e redução dos impactos causados na produção de frutas. Uma alternativa que simplifica este procedimento é a identificação automática das asas através de técnicas de reconhecimento de padrões, combinado a técnicas de processamento de imagens e *machine learning*. De acordo com [4], o reconhecimento de padrões computacionais tem sido amplamente estudado em diversas aplicações, principalmente para a classificação de amostras em grupos.

Uma vez exposta a relevância do estudo proposto, o principal objetivo a ser alcançado com o trabalho é a extração de características de forma automática, em imagens segmentadas das asas de moscas da família *Drosophilidae*, dos gêneros *Drosophila*, *Hirtodrosophila*, *Dichactophora*, *Lidrosophila* e *Scaptomyza*, para identificação das fêmeas da espécie *Drosophila suzukii*, a partir de técnicas de extração de características e implementação de algoritmos classificadores.

Além disso será analisada a combinação de técnicas eficientes de extração de características e classificadores, validação da metodologia proposta e dos resultados obtidos por meio de um comparativo de desempenho dos classificadores utilizados

para a solução do problema descrito.

II. TRABALHOS RELACIONADOS

Estudos que utilizam *softwares* para classificação de imagens de asas de insetos são recentes. No gênero *Drosophila*, uma das moscas mais pesquisada é a *Drosophila melanogaster*. Ao longo dessa seção serão apresentados trabalhos relacionados que utilizam técnicas semelhantes para processamento digital de imagens de asas de insetos e classificadores.

Em [5], o autor utilizou em seu trabalho a *Drosophila melanogaster* e aplicou um método de discriminação de gênero e genótipo a partir das características extraídas das asas. Seis classificadores de abordagens diferentes foram testados: Floresta Aleatória (RF), Máquina de Vetor de Suporte (SVM), K-Vizinhos Mais Próximos (KNN), Análise por Discriminante Linear (LDA), Análise por Discriminante Quadrático (QDA) e Perceptron Multicamadas (MLP).

Como mencionado em [5], os resultados obtidos foram satisfatórios e ultrapassaram trabalhos da literatura com metodologias que não necessitam da ação humana. O autor usou um *dataset* composto por aproximadamente 2780 imagens de machos e fêmeas. O melhor desempenho foi obtido com o classificador SVM com uma acurácia de 88,15%.

Em [4] os autores elaboraram um trabalho comparativo entre os *softwares* *BioCat* (Ferramenta de Classificação e Anotação de Bioimagem) e *WINGMACHINE*. O *BioCat* permite a realização de combinações de seletores de recursos, extratores e classificadores, além de ferramentas de anotações e um estrutura de suporte a imagens em duas ou três dimensões. Os testes utilizando o primeiro *software* obtiveram uma média de 80% de taxa de acerto para classificações de gênero, e 52% para genótipo. Os testes com o segundo alcançaram resultados melhores: acima dos 90% para os teste com gênero e mais de 80% para os testes de genótipo. O *WINGMACHINE* exige a marcação dos pontos de referência na imagem, o que exige um especialista da área para tal tarefa. Os classificadores usados no trabalho foram: LDA, QDA, Análise por Discriminante Flexível (FDA), Análise por Discriminante Múltiplo (MDA), *Bagging*, Floresta Aleatória, SVM, KNN e Redes Neurais Artificiais.

A espécie *melanogaster* foi usada para classificação de gênero baseado na textura das asas em [6]. Os autores compararam os extratores de características Padrão Binário Local Modificado (MLBP) e Padrão Binário Local (LBP) usando SVM e RF. Obtendo a melhor acurácia de 94% com MLBP e SVM, e uma acurácia média de 90% com MLBP e Floresta Aleatória (RF). O *dataset* manipulado possuía cerca de 500 imagens, dividido igualmente entre machos e fêmeas.

III. FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentados breves resumos dos principais conhecimentos necessários para desenvolvimento do trabalho. Os conceitos abordados são reconhecimento de padrões em imagens, definições da Transformada Wavelet Estacionária (TWE), filtro de Canny, dimensão fractal. Os algoritmos classificadores usados não serão detalhados nesta seção, dado o seu uso exaustivo nos últimos anos na literatura.

A. Reconhecimento de padrões em imagens

Reconhecimento de padrões é uma das funções mais realizadas pela área de Inteligência Artificial [7]. A importância dessa técnica está relacionada à procura por métodos informatizados e automatizados para tarefas realizadas iterativas, exaustivas e sujeitas a muitas falhas por humanos [8], como a identificação de espécies de moscas através das asas.

O objetivo primordial do reconhecimento de padrões é reconhecer objetos por meio da extração de características. De acordo com [9], os problemas dessa natureza podem ser agrupados de duas formas: classificação e regressão. Na classificação as classes ou categorias das novas entradas são agrupadas em categorias definidas antecipadamente. Neste trabalho será abordado um problema de classificação.

O trabalho é dividido em duas etapas, de acordo com [10]: o pré-processamento e o reconhecimento em si. Na primeira fase as imagens são submetidas a uma série de transformações com o intuito de retirar características intrínsecas, que permite o trabalho de classificação realizado posteriormente, eliminar ruídos e informações inúteis que possam atrapalhar o processo de classificação [11].

O pré-processamento em imagens digitais é dividido em duas etapas distintas: segmentação de imagens e extração de características que serão processados. Na segmentação o objeto estudado é separado dos outros elementos presentes na imagem. Na fase de extração são selecionados atributos importantes da imagem. Essa ação forma um vetor de características que representa de modo resumido a imagem. Dessa forma, é possível reduzir a quantidade de informação necessária para a classificação e, por consequência, o tempo de processamento para realizar a tarefa [7].

Conforme [12], a estrutura básica de um sistema de reconhecimento de padrões em imagens pode ser composta pelas seguintes etapas, descritas na Figura 2. As etapas não são fixas, podem ser alteradas, removidas ou outras acrescentadas, de acordo com a necessidade da aplicação. A metodologia apresentada neste texto segue essa sequência, como pode ser visto na próxima seção.


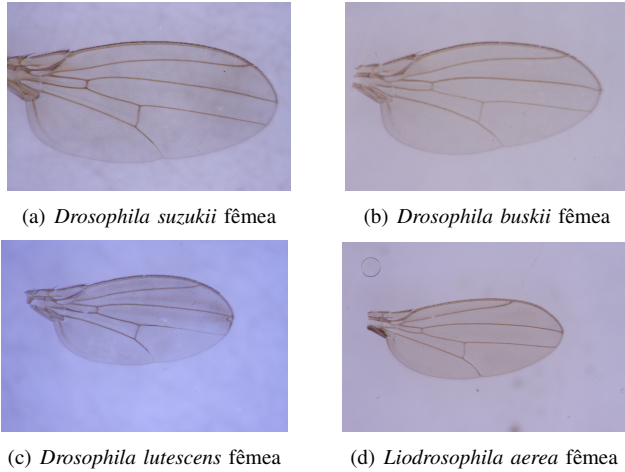


Figura 2. Arquitetura básica de um sistema de reconhecimento de imagens

B. Base de Imagens

A base de imagens utilizada neste trabalho foi obtida de [13], disponível em [14] com 600 imagens de asas de moscas da família *Drosophilidae*, dos gêneros *Drosophila*, *Hirtodrosophila*, *Dichactophora*, *Liodrosophila* e *Scaptomyza*.

As imagens foram coletadas na floresta do *campus* Minami-osawa pertencente a *Tokyo Metropolitan University*. Uma asa unilateral foi retirada de cada indivíduo.



C. Transformada Wavelet

Conforme [15], em seu trabalho define *Wavelets* como funções que atendem requisitos matemáticos aplicados na representação de dados ou outras funções. A *wavelet* é capaz de ser executada em diferentes escalas ou resoluções. Segundo [16], é uma técnica para estudo de particularidades invisíveis em certas escalas nos componentes da *wavelet* estabelecidos em espaço e escala, devido sua estrutura de representação combinada de tempo e frequência. Esse tipo de transformada pode analisar séries contínuas ou discretas de escalas, denominadas respectivamente de Transformada *Wavelet* Contínua (TWC) e Transformada *Wavelet* Disceta (TWD).

Na metodologia proposta neste trabalho foi utilizada a TWD de Haar em dois níveis de decomposição. A Transformada *Wavelet* de Haar pertence à família de funções *wavelets Daubechies* [17]. A transformada mencionada acima foi implementada na metodologia proposta por [5] para classificação das asas da mosca *melanogaster*. Conforme o autor, é considerada simples e de rápida execução, além de apresentar resultados acurados em remoção de ruídos. Porém, é considerada ineficiente para determinadas aplicações por não ser suave.

D. Filtro de Canny

Segundo [18], as bordas compõe informação de alta frequência e limitam características importantes de uma imagem. Estas características abrangem descontinuidades fotométricas, geométricas e propriedades físicas dos objetos. Para que se alcance resultados acurados nas etapas posteriores, a detecção de bordas é uma etapa essencial que necessita de uma técnica eficiente e confiável.

O processo de detecção de bordas Canny, desenvolvido por John Canny em 1986, é fundamentado em dois parâmetros elementares de desempenho: detecção e localização. A finalidade do trabalho produzido por Canny é a elaboração de um detector ótimo para o tipo de bordas mais frequente em

imagens digitais, as bordas do tipo degrau. O operador ótimo é obtido através da primeira derivada da função Gaussiana.

Uma borda do tipo degrau pode ser equacionada matematicamente por:

$$G(x) = Au_{-1}(x), \quad (1)$$

em que A é a amplitude da borda e $u_{-1}(x)$ é expressa por:

$$u_{-1}(x) = \begin{cases} 0, & \text{para } x < 0 \\ 1, & \text{para } x \geq 0. \end{cases}$$




Figura 3. Exemplo de uso do filtro de Canny

Na Figura 3 é exemplificado a utilização do filtro de detecção de borda elaborado por Canny e os resultados obtidos a partir da variação do valor do parâmetro σ do filtro gaussiano. O desvio padrão σ faz parte da equação da função gaussiana, a alteração desse valor permite aumentar ou reduzir o nível de precisão da detecção das bordas.

E. Dimensão Fractal

Posteriormente a etapa de segmentação das imagens, é realizado o passo de extração de características. Dimensão Fractal (DF) é um exemplo de técnica utilizada com essa finalidade.

De acordo com [19], na geometria euclidiana clássica, a dimensão é interpretada com um número natural que descreve a quantidade de direções que cada diferencial do objeto ocupa no espaço. Dessa maneira, um ponto possui dimensão 0, a linha dimensão 1, um plano tem duas dimensões e um sólido, conseqüentemente, dimensão 3. Já na DF, essa quantidade é fracionária, intermediária entre duas dimensões euclidianas.

Conforme [5], uma aproximação dessa dimensão é realizada através do método denominado *box-counting* ou dimensão de Minkowski-Bouligand, obtido através do cálculo abaixo:

$$d \sim -\frac{\log N(\varepsilon)}{\log \varepsilon}, \quad (2)$$

considerando $N(\varepsilon)$ a quantidade de caixas de tamanho ε necessárias para preencher a imagem.

IV. METODOLOGIA

Ao longo desta seção será apresentada em detalhes a metodologia proposta neste trabalho para extração de características e classificação das asas de mosca. A abordagem definida tem início com a aquisição das imagens, em seguida ocorre o tratamento, extração das características, classificação e análise

dos resultados. Por fim, são apresentadas informações sobre o processo de implementação do algoritmo.

A Figura 4 detalha a sequência de passos realizados no trabalho proposto, as etapas foram divididas em quatro. O estágio 1 apresentado na Figura 4(a) realiza o pré-processamento das imagens utilizadas para treinamento e teste, o passo seguinte mostrado na Figura 4(b) obtém os resultados da aplicação da Transformada de *Wavelet*. Sequencialmente na Figura 4(c) é realizado a detecção de bordas através do filtro de Canny. Por fim, a Figura 4(d) mostra os passos finais para obtenção da classificação. As etapas descritas são aprofundadas nos tópicos seguintes.

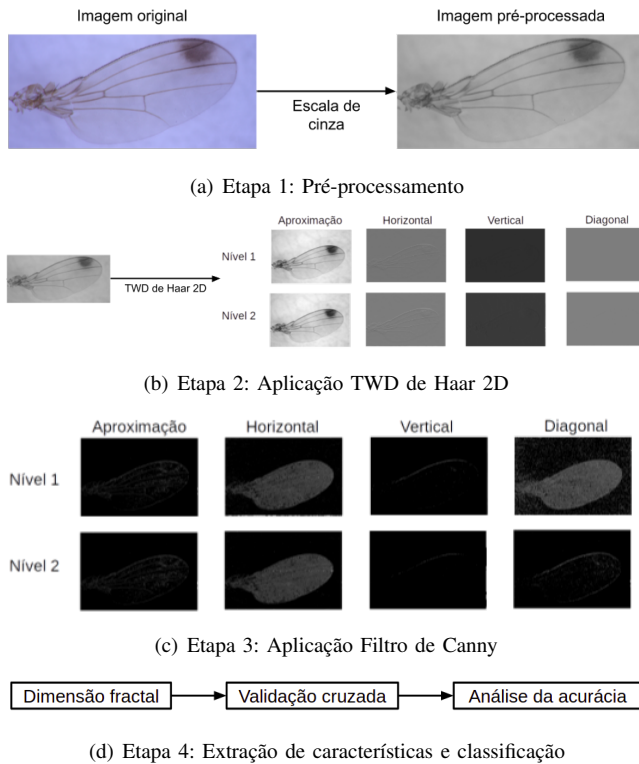


Figura 4. Etapas da metodologia aplicada

A. Pré-processamento

A primeira etapa da metodologia proposta é o pré-processamento das imagens. As imagens utilizadas neste trabalho são originalmente coloridas e apresentam pouco ruído, a partir dessas informações, o primeiro procedimento adotado foi a conversão de todas as imagens utilizadas para escala de cinza. Por não apresentar imagens muito ruidosas julgou-se não utilizar nenhuma técnica a mais na etapa de pré-processamento, como alguma técnica de filtragem.

B. Extração de características

Após a etapa anterior, a imagem é decomposta com TWD de Haar de 2 níveis. Cada nível gera quatro componentes: aproximação, horizontal, vertical e diagonal, ou seja, ao fim dos processamento da transformada são obtidos oito saídas. Para cada componente são detectadas bordas utilizando o filtro

de Canny. Após exaustivos testes observou-se que o valor adequado para o conjunto de imagens analisadas foi $\sigma = 1,0$, portanto, em todas as componentes foi usado tal valor. A dimensão fractal é extraída de cada imagem binarizada resultante, gerando um vetor de oito posições.

C. Classificação de cenários

O *dataset* analisado é composto por 600 imagens. Para realizar o treinamento e testes com os classificadores detalhados anteriormente foram considerados os seguintes cenários e técnicas:

- **Cenário A:** As moscas foram classificadas em dois conjuntos, portanto os *targets* possuem os valores 0 ou 1. O valor 0 representa todo o universo de moscas que não são da espécie *Drosophila suzukii*.
- **Cenário B:** A segunda situação além de identificar as moscas da espécie *suzukii*, também tem o objetivo de diferenciar os machos e fêmeas da referida mosca. Sendo assim foram considerados três valores de classificação, 0 para qualquer mosca que não fosse a *Drosophila suzukii*, 1 para representar as *suzukii* fêmeas e 2 para os machos dessa espécie.

Além desses dois cenários apresentados, foram considerados dois métodos, *K-Fold* e *Leave One Out (LOO)*, para realizar o particionamento do conjunto de imagens entre dados para treino e dados para teste, avaliar a capacidade de generalização de cada classificador e o quão acurados são os modelos nesse problema específico. Os métodos serão mais bem detalhados mais adiante.

Cada cenário foi testado com ambos os métodos, com 10 rodadas em cada um dos classificadores analisados e a taxa de erro obtida é comparada com os demais resultados. Na Figura 5 é mostrado o fluxograma dos testes realizados considerando os cenários propostos e técnicas de validação cruzada analisadas.




Figura 5. Fluxograma da divisão dos cenários e técnicas de validação para classificação

D. Técnicas de validação cruzada

Os testes com classificadores normalmente são realizados de acordo com as seguintes etapas:

- 1) O classificador é treinado com um do conjunto de dados conhecido como dados de treinamento. Após isso é gerado um modelo ou também chamado de preditor.
- 2) O modelo criado é testado com os chamados dados de teste, no qual já se conhece a classificação para cada amostra.

3) O resultado dessa classificação feita pelo preditor é então comparado com o resultado correto, aquele que já se conhecia, e assim é possível analisar a quantidade de acertos e erros. A partir disso se extrai métricas para avaliar a qualidade do modelo obtido.

Porém, a quantidade de dados disponíveis pode não ser suficientemente grande para particionar os dados em conjuntos para treino e teste de forma a obter métricas confiáveis para análise do modelo proposto [20]. Normalmente o conjunto de dados é dividido em 80% dos dados para treino e 20% para teste ou em 70% destinado para treinamento e os outros 30% para teste, porém é possível que algumas amostras relevantes não sejam treinados pelo modelo, o que gera previsões ruins. Uma alternativa para isso é utilizar a validação cruzada.

Duas abordagens populares para avaliação de desempenho de algoritmos de classificação são os supracitados métodos de validação cruzada *K-Fold* e *Leave One Out* [20].

A ideia principal do método *K-Fold* é particionar o conjunto de dados disponíveis em *k* partições, ou *folds*, e realizar *k* rodadas de treinamento e testes com essas combinações de dados, como demonstrado na figura 6. A técnica permite que pelo menos uma vez cada *k-fold* seja usado como conjunto de dados de treinamento. Dessa forma, são minimizadas as chances de dados relevantes para a classificação não estarem no conjunto de treinamento. Ao fim da execução das *k* rodadas será obtida uma pontuação média de acertos.

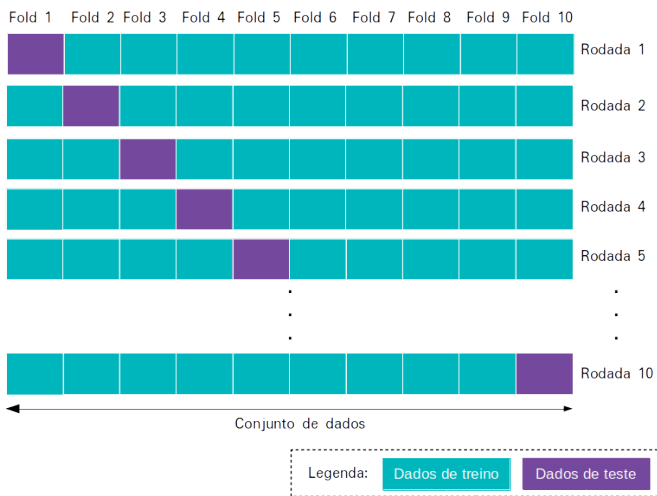


Figura 6. Funcionamento do método *K-Fold*

Já o método LOO é recomendado, conforme [20], para avaliar modelos no qual o conjunto de dados é pequeno ou uma determinada classe possui um número reduzido de amostras quando comparando as demais do *dataset*, como é o caso abordado neste trabalho e explicado na próxima seção.

O método possui funcionamento semelhante ao *K-Fold* com a diferença que o treinamento é realizado com $(n-1)$ dados e o teste com 1 dos registros somente, ou seja, a técnica define o número de subconjuntos igual ao número de registros da base de dados [21], como é possível observar na Figura 7. No

caso tratado neste trabalho há 600 amostras, sendo assim, são definidos 600 subconjuntos, cada um com uma amostra para teste. Segundo [20], como a aleatoriedade de instâncias de divisão em treinamento e teste não existe, a estimativa pontual de precisão para um dado conjunto de dados é constante.

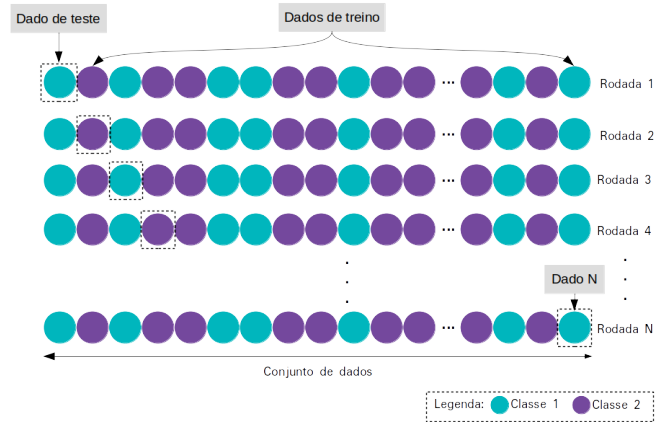


Figura 7. Funcionamento do método LOO

E. Implementação

O sistema foi desenvolvido inteiramente em *Python* com utilização da biblioteca *scikit-image* para processamento das imagens e segmentação por meio do filtro de Canny, *numpy* para a realização dos cálculos matemáticos, manipulação dos dados e cálculo da DF. A biblioteca *scikit-learn* foi usada para implementação dos métodos classificadores.

Algumas funções utilizadas do *scikit-image* são executadas apenas em imagens em nível de cinza, devido a isso a etapa descrita na IV-A foi necessária. A linguagem e bibliotecas utilizadas, bem como os códigos usados como auxílio, são gratuitos e de código-fonte aberto.

Os valores utilizados para σ no filtro de Canny e nos parâmetros dos classificadores foram encontrados por meio de testes e tentativas exaustivas. Segue algumas informações relevantes sobre isso: $\sigma = 1.0$, KNN com número de vizinhos igual a 2, SVM com *kernel* linear de grau 3, LDA, QDA e DT foram utilizados com os parâmetros *default* e RF com 10 árvores.

V. RESULTADOS E DISCUSSÕES

Esta seção expõe os resultados dos testes realizados, com objetivo de comparar o desempenho dos algoritmos de classificação, técnica de extração de características e os métodos de validação cruzada apresentados anteriormente.

A. Validação cruzada: K-Fold

Na Tabela I são exibidos os resultados das taxas de acerto máximo e médio para os seis algoritmos de classificação em ambos os cenários descritos previamente, usando a técnica de validação cruzada *K-Fold*. No método *K-Fold* foi utilizado *k* com valor igual a dez.

Os dados do cenário A foram classificados em 1 para as moscas *suzukii*, sem distinção de gênero, e 0 para as

Tabela I
ACERTOS OBTIDOS COM A METODOLOGIA PROPOSTA UTILIZANDO O
MÉTODO K-FOLD

Classificador	Cenário	Acerto médio (%)	Desvio padrão
KNN	A	91.99	3.92
SVM		93.15	3.22
LDA		93.32	1.98
QDA		93.16	3.53
AD		90.82	4.54
RF		93.17	3.53
KNN	B	91.49	2.03
SVM		93.16	2.17
LDA		92.48	3.76
QDA		91.49	3.52
AD		87.49	4.35
RF		93.16	3.90

demais espécies, portanto uma classificação binária. Dessa forma, a classe 0 possui 556 dados e a classe 1, 44 dados classificados. O classificador com melhor desempenho nas condições descritas foi o LDA, com taxa de acerto média de 93.32%, como observado na terceira linha da tabela I. O segundo melhor resultado, Floresta Aleatória, obteve taxa de acerto médio de 93.16%. O preditor Árvore de Decisão obteve a taxa de acerto média mais baixa que os demais, 90.82% com desvio padrão de 4.54.

No cenário B, o gênero das moscas de asa manchada são considerados, dessa forma como já explicado, têm-se três possíveis classificações:

- 0 para as demais moscas de outras espécies, sem realizar a distinção de gênero,
- 1 para as fêmeas da *suzukii*, a classe possui 22 amostras
- 2 para os machos da espécie alvo, a classe também possui 22 exemplares

Nestas circunstâncias, os algoritmos SVM e RF obtiveram as melhores médias de taxa de acerto, 93.16%. A taxa de acerto máximo atingiu maior valor com o preditor RF, 98.31%, o valor do desvio padrão também foi maior, 3.90, o que pode indicar uma maior dispersão dos valores. A partir dessa observação, o SVM é considerado o melhor classificador nessas condições.

B. Validação cruzada: Leave One Out

As mesmas condições descritas na seção V-A foram feitas para os testes utilizando o método de validação cruzada *Leave One Out*, os resultados são exibidos na Tabela II.

No cenário A, a melhor média de acerto, 93.42%, foi obtida com preditor Floresta Aleatória. O algoritmo Árvore de Decisão obteve a menor taxa, 88.15%. Considerando o caso B, o melhor comportamento foi obtido pelo SVM com taxa de 93.14%. Árvore de Decisão novamente apresentou a menor taxa de acerto em comparação com os demais algoritmos. Os valores de acerto máximo de 100% são esperados para a técnica em análise, tendo em vista que cada amostra é testada e portanto, o algoritmo acerta ou não a sua a classe.

Tabela II
ACERTOS OBTIDOS COM A METODOLOGIA PROPOSTA UTILIZANDO O
MÉTODO LOO

Classificador	Cenário	Acerto médio (%)	Desvio padrão
KNN	A	91.49	27.91
SVM		93.17	25.25
LDA		93.16	25.25
QDA		93.15	25.26
AD		88.15	32.31
RF		93.42	24.98
KNN	B	91.32	28.16
SVM		93.14	25.25
LDA		92.49	26.36
QDA		91.49	27.91
AD		87.81	32.71
RF		92.65	26.09

C. TW de Haar nível 1

Além dos testes apresentados para as duas técnicas de validação cruzada consideradas foram realizados dois testes adicionais a fim de compreender o impacto da etapa de extração características para classificação das asas das moscas testadas. O objetivo foi compreender o quão influente é o tamanho do vetor de características nesse tipo de aplicação.

O primeiro teste foi realizado com as componentes obtidas pela Transformada de *Wavelet* de Haar no primeiro nível, portanto, o vetor de características possuía quatro valores. Os resultados obtidos são mostrados nas Tabelas III e IV.

Tabela III
ACERTOS OBTIDOS COM MÉTODO K-FOLD - TW DE HAAR (NÍVEL 1)

Classificador	Cenário	Acerto médio (%)	Desvio padrão
KNN	A	91.80	3.02
SVM		93.10	1.74
LDA		92.82	2.59
QDA		88.48	4.68
AD		88.90	2.58
RF		92.83	3.65
KNN	B	91.81	4.16
SVM		93.12	2.83
LDA		92.32	3.09
QDA		87.98	3.32
AD		88.48	4.17
RF		92.31	5.12

No geral, os resultados mostrados na Tabela III obtiveram um desempenho mais baixo quando comparados com os valores exibidos na Tabela I, no qual são considerados o vetor de características com ambos os níveis, ou seja, um vetor com oito valores. Apesar disso, os valores exibidos na Tabela III apresentam desempenho satisfatório.

Os resultados mostrados na Tabela IV expõem dados semelhantes aos valores apresentados nas tabelas anteriores. Em ambos os testes desta seção, o classificador SVM é apontado como melhor algoritmo para o problema analisado.

Tabela IV
ACERTOS OBTIDOS COM MÉTODO LOO - TW DE HAAR (NÍVEL 1)

Classificador	Cenário	Acerto médio (%)	Desvio padrão
KNN	A	91.49	27.91
SVM		93.15	26.25
LDA		92.13	26.89
QDA		88.81	31.52
AD		88.48	31.93
RF		92.65	26.09
KNN	B	91.64	27.91
SVM		93.14	25.63
LDA		92.48	26.36
QDA		88.65	31.72
AD		88.63	31.78
RF		92.91	25.53

D. TW de Haar de nível 2

O segundo experimento adicional realizado, como já supracitado, considerou as componentes apenas do nível 2 para cálculo da dimensão fractal e obtenção do vetor de características. Os valores de acurácia conseguidos por meio dos métodos *K-fold* e LOO estão expostos na Tabela V.

Tabela V
ACERTOS OBTIDOS COM MÉTODO K-FOLD - TW DE HAAR (NÍVEL 2)

Classificador	Cenário	Acerto médio (%)	Desvio padrão
KNN	A	91.65	4.09
SVM		93.15	3.55
LDA		93.01	3.31
QDA		93.10	2.83
AD		87.66	4.15
RF		92.99	2.76
KNN	B	90.99	3.88
SVM		93.16	3.69
LDA		92.32	2.23
QDA		91.48	3.69
AD		87.47	4.21
RF		91.98	2.88

A constância dos valores médios de acurácia em torno dos 90% se mantém. Repetidamente, o classificador SVM obteve as melhores taxas de acerto média em ambos os cenários considerados. O preditor AD obteve novamente taxas menores quando comparado aos demais, nos dois casos analisados.

Por fim, tem-se os dados exibidos na Tabela VI obtidos dos testes utilizando a técnica LOO. Similar aos dados apresentados nas tabelas anteriores, o SVM obteve melhores taxas de acerto no caso A e B. Da mesma forma para o classificador com desempenho mais baixo, Árvore de Decisão.

Tendo em vista os resultados apresentados é possível perceber a pouca variação da taxa de acerto média dos métodos de validação cruzada. Sabendo que o método LOO demanda mais recursos de tempo e processamento para execução do treinamento, tendo em vista a descrição feita na seção IV-D, o método *K-Fold* se mostra mais eficiente para uso na abordagem de problemáticas desse tipo. Considerando essa

Tabela VI
ACERTOS OBTIDOS COM MÉTODO LOO - TW DE HAAR (NÍVEL 2)

Classificador	Cenário	Acerto médio (%)	Desvio padrão
KNN	A	91.49	27.91
SVM		93.13	25.22
LDA		93.12	25.25
QDA		93.08	24.89
AD		88.31	32.13
RF		92.49	26.36
KNN	B	91.32	28.16
SVM		93.16	25.25
LDA		92.49	26.36
QDA		91.48	27.91
AD		87.47	31.93
RF		93.11	25.20

informação a Tabela VII exhibe um resumo dos melhores resultados dos testes realizados e apresentados ao longo das seis tabelas anteriores.

A partir da Tabela VII é possível afirmar que o algoritmo SVM possui o melhor desempenho para classificação de dados nas condições especificadas ao longo deste texto, além disso houve pouca variação de acerto entre com os vetores de características obtidos apenas com o nível 1 ou 2 da TW.

Tabela VII
RESUMO COM OS MELHORES RESULTADOS

Cenário	TW nível	Características	Classificador	Acerto médio
A	1	4	SVM	93.10
	2	4	SVM	93.15
	1 e 2	8	LDA	93.32
B	1	4	SVM	93.12
	2	4	SVM	93.16
	1 e 2	8	SVM	93.16

VI. CONCLUSÃO

Este trabalho sugeriu uma metodologia para classificação da *Drosophila suzukii* em relação a outras moscas, com objetivo de identificar as fêmeas da espécie, causadoras de prejuízos consideráveis a culturas de frutas pequenas e de pele macia, a partir da extração de características de imagens das asas.

A classificação por gênero se mostrou eficiente, obtendo taxas de acerto superior a 90% na maioria dos classificadores analisados, em ambos os métodos de validação cruzada implementados. Os resultados de acurácia quando o número de atributos no vetor de características foi reduzido, utilizando apenas o nível 1 ou nível 2 dos componentes gerados pela TW de Haar, também foram satisfatórios. A classificação por espécies obteve resultados de acertos eficientes nos testes realizados, comprovando a aplicabilidade da metodologia proposta para resolução de problemática semelhante à explicitada ao longo deste texto.

Nos testes realizados e apresentados na seção anterior, os classificadores SVM, LDA e RF conseguiram os melhores valores médios de acurácia, em ambos os cenários definidos.

Árvore de Decisão foi considerado o pior modelo para esse tipo de abordagem, nos cenários A e B, em todos os testes realizados. A utilização da técnica de validação cruzada *K-Fold* apresentou pouca divergência em relação ao método *Leave One Out*. Diante disso e de o fato do LOO demandar um custo computacional maior, a escolha do método *K-Fold* é mais interessante.

Os valores encontrados e os classificadores que obtiveram melhores pontuação de acurácia são compatíveis com os resultados encontrados nos trabalhos [5] e [6], que alcançaram taxas de 95.55% e 94%, respectivamente, com o SVM, para a classificação por gênero.

A partir dos resultados obtidos é possível verificar que a metodologia sugerida para extração de características e classificação é satisfatória, com capacidade de obter boas médias de acurácia sem a necessidade da interação humana para realização desta tarefa, além de mostrar taxas de acertos condizentes com valores indicados em outros trabalhos da literatura. Dessa forma é validada a eficiência das técnicas escolhidas para a abordagem explanada, com os objetivos especificados no trabalho alcançados com êxito.

AGRADECIMENTOS

Agradecimentos a Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (Funcap) pelo financiamento da pesquisa via bolsa de estudos.

REFERÊNCIAS

- [1] D. E. Nava, M. Botton, D. Bernardi, F. Erezza, and C. A. Baronio, "Bioecologia, monitoramento e controle de drosophila suzukii na cultura do morangueiro," *Embrapa Clima Temperado-Documentos (INFOTECA-E)*, 2015.
- [2] D. Schlesener, J. Wollmann, A. Nunes, J. Cordeiro, M. Gottschalk, and F. Garcia, "Drosophila suzukii: nova praga para a fruticultura brasileira," *O Biológico*, vol. 77, no. 1, pp. 47–54, 2015.
- [3] F. A. Müller and D. E. Nava, "Primeiro relato de drosophila suzukii (diptera: Drosophilidae) em frutos de araçá e pitanga em municípios da região sul do rio gree do sul, brasil." in *Embrapa Clima Temperado-Resumo em anais de congresso (ALICE)*. In: CONGRESSO BRASILEIRO DE ENTOMOLOGIA, 25., 2014, Goiânia, GO., 2014.
- [4] A. Sonnenschein, D. VeerZee, W. R. Pitchers, and I. Chari, Sudarshan e Dworkin, "An image database of drosophila melanogaster wings for phenomic and biometric analysis," *GigaScience*, vol. 4, no. 1, p. 25, 2015.
- [5] F. G. M. Neto, "Extração automática de características de asas de mosca da espécie drosophila melanogaster," Master's thesis, Dissertação - Universidade Federal do Ceará, 2017.
- [6] F. Ahmad, K. Roy, B. O'Connor, J. Shelton, G. Dozier, and I. Dworkin, "Fly wing biometrics using modified local binary pattern, svms e reom forest," *International Journal of Machine Learning e Computing*, vol. 4, no. 3, p. 279, 2014.
- [7] F. C. Moreira *et al.*, "Reconhecimento e classificação de padrões de imagens de núcleos de linfócitos do sangue periférico humano com a utilização de redes neurais artificiais," 2002.
- [8] C. Spínola, "Correlação iridológica entre cérebro e intestino," *Monografia, FACIS-IBEHE, São Paulo*, 2004.
- [9] C. M. Bishop, *Pattern recognition e machine learning*. Springer, 2006.
- [10] C. M. Bishop *et al.*, *Neural networks for pattern recognition*. Oxford University Press, 1995.
- [11] A. E. SCURI, "Fundamentos da imagem digital," *Universidade Pontifícia Católica do Rio de Janeiro*, 1999.
- [12] K. R. Castleman, *Digital Image Processing*. Upper Saddle River: Prentice Hall, Inc., 1996.
- [13] S. Y. M. Loh, Y. Ogawa, S. Kawana, K. Tamura, and H. K. Lee, "Semi-automated quantitative drosophila wings measurements," *BMC Bioinformatics*, 2017.
- [14] U. o. W. Wisconsin, "Biology of the Spotted Wing Drosophila," 2019, disponível em: <<http://labs.russell.wisc.edu/swd/biology/>>. Acesso em: 02 abril 2019.
- [15] C. R. Castelano, "Estudo comparativo da transformada wavelet no reconhecimento de padrões da íris humana," Ph.D. dissertation, Universidade de São Paulo, 2006.
- [16] L. Ebadi and H. Z. Shafri, "A stable and accurate wavelet-based method for noise reduction from hyperspectral vegetation spectrum," *Earth Science Informatics*, vol. 8, no. 2, pp. 411–425, 2015.
- [17] W. H. Shirado, M. de Abreu Moreira, J. G. Palma, and S. B. Júnior, "Estudo comparativo entre algoritmos das transformadas discretas de fourier e wavelet," *Revista Brasileira de Computação Aplicada*, vol. 7, no. 3, pp. 97–107, 2015.
- [18] G. Maia and V. A. Porfírio, "O processo de detecção de bordas de canny: fundamentos, algoritmos e avaliação experimental," 2002.
- [19] O. M. Bruno, R. de Oliveira Plotze, M. Falvo, and M. de Castro, "Fractal dimension applied to plant identification," *Information Sciences*, vol. 178, no. 12, pp. 2722–2733, 2008.
- [20] T.-T. Wong, "Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation," *Pattern Recognition*, vol. 48, no. 9, pp. 2839–2846, 2015.
- [21] J. N. C. Schreiber, A. L. Beskow, J. C. T. Müller, E. O. B. Nara, J. I. D. Silva, and J. W. Reuter, "Técnicas de validação de dados para sistemas inteligentes: abordagem do software sdbayes," 2017.