

Análise da Autocorrelação no reconhecimento de moscas-das-frutas pelo sinal bioacústico de batimento de asas

Fabiano Sandrini Moraes

Programa de Pós-Graduação em Computação
Universidade Federal de Pelotas)

Pelotas, Brasil

fabianomoraes@ifsul.edu.br

Dori Edson Nava

Embrapa Clima Temperado
Pelotas, Brasil

dori.edson-nava@embrapa.br

Ricardo Matsumura de Araujo

Programa de Pós-Graduação em Computação
Universidade Federal de Pelotas

Pelotas, Brasil

ricardo.araujo@ufpel.edu.br

Orhan Bittencourt Fernandes da Silva

Curso Engenharia Elétrica

Instituto Federal de Educação, Ciência e Tecnologia Sul-rio-grandense

Pelotas, Brasil

orhanorhanbittencourt@gmail.com

Resumo—Este estudo avalia o uso da Autocorrelação como técnica de extração de características em um sistema de reconhecimento de moscas-das-frutas por meio de seus sinais bioacústicos de batimento de asas. Para isso, foi gerado um conjunto de dados com as moscas-das-frutas *Anastrepha fraterculus* e *Ceratitis capitata* utilizando um sensor optoeletrônico próprio. As características utilizadas para a classificação foram a frequência fundamental obtida por Autocorrelação e FFT, além do espectro de frequência obtido por FFT. Os resultados indicam que o uso da frequência fundamental obtida por FFT e Autocorrelação melhora o desempenho do sistema de classificação (sensibilidade de 96% com RF), apresentando resultados próximos ao uso do espectro de frequência (sensibilidade de 97% com SVM).

Palavras-chave—Autocorrelação, Moscas-das-frutas, Aprendizado de Máquina, Bioacústica, Batimento de asas

I. INTRODUÇÃO

A fruticultura brasileira é reconhecida mundialmente por sua diversidade e abrangência, ocupando mais de dois milhões de hectares de terras cultivadas em todo o país e contribuindo com uma receita anual de aproximadamente 33 bilhões de reais. Além disso, essa importante cadeia produtiva gera mais de cinco milhões de empregos, especialmente em regiões onde outras atividades agrícolas seriam inviáveis do ponto de vista econômico, como o semiárido brasileiro [1].

Um dos principais desafios enfrentados pela fruticultura é o controle das moscas-das-frutas, que podem causar perdas de até 100% na produção. Globalmente, estima-se que essas pragas causem prejuízos que ultrapassam um bilhão de dólares, e apenas no Brasil, o prejuízo estimado pode chegar a mais de 242 milhões de dólares [2].

As moscas-das-frutas, como *Anastrepha fraterculus* (Wiedemann, 1830), *Ceratitis capitata* (Wiedemann, 1824) e *Bactrocera carambolae* (Drew e Hancock, 1994), estão presentes em todo o território nacional e atacam uma ampla variedade

de frutas, sendo consideradas as principais em termos de importância econômica e quarentenária [3].

Para controlar essa praga, os produtores devem realizar o monitoramento do pomar para identificar a espécie e o nível de infestação, a fim de determinar as medidas de controle adequadas. O monitoramento é geralmente realizado utilizando armadilhas, sendo recomendado o uso de 2 a 4 armadilhas por hectare. A inspeção das armadilhas é feita manualmente por um técnico especializado uma vez por semana. Quando o número de moscas capturadas atinge 0,5 moscas por armadilha por dia, o produtor deve iniciar as medidas de controle [4].

No entanto, o monitoramento manual das moscas-das-frutas apresenta algumas limitações, como a necessidade de técnicos treinados para a inspeção, classificação e contagem das moscas, resultando em altos custos. Além disso, há o risco de erros humanos na classificação e atrasos na detecção da presença das moscas, devido aos intervalos entre as inspeções. Por causa dessas limitações, muitos produtores optam por um controle preventivo, usando inseticidas em forma de iscas-tóxicas ou pulverização em todo o pomar. No entanto, essa abordagem causa impacto ambiental, deterioração na qualidade dos frutos, restrições na exportação devido a resíduos químicos e aumento nos custos de produção [4].

As armadilhas inteligentes são uma alternativa ao monitoramento manual, permitindo o reconhecimento automático das moscas-das-frutas. Essa tecnologia reduz a intervenção humana, minimiza erros de identificação e custos. Além disso, pode fornecer dados em tempo real, permitindo uma tomada de decisão ágil. As armadilhas inteligentes podem funcionar tanto como uma ferramenta complementar aos técnicos, para validar os resultados obtidos, quanto como o principal método de monitoramento em situações em que a presença física de um técnico é inviável. Essa abordagem contribuirá para a

popularização da Agricultura Digital, especialmente entre os pequenos e médios produtores, contribuindo para um controle eficaz da praga das moscas-das-frutas.

O reconhecimento de insetos por imagem esteve na vanguarda na classificação de insetos. No entanto, nos últimos anos, os métodos bioacústicos têm ganhado destaque nessa área. O reconhecimento por bioacústica, que já era utilizada em aves e mamíferos, agora está sendo aplicada a grupos menos conhecidos e altamente diversificados, como os insetos [5]. No caso das moscas-das-frutas, é possível aproveitar o som bioacústico gerado pelo batimento de asas como uma forma de detecção e classificação [6].

Na última década, vários estudos têm proposto métodos para o reconhecimento de insetos com base no sinal bioacústico do batimento de asas. A maioria desses estudos tem se concentrado na classificação de mosquitos, como pode ser visto em [8] e [9]. No entanto, para as moscas-das-frutas, existem apenas alguns estudos relacionados à *B. oleae*, como em [10], [7] e [11].

No entanto, mesmo com esses avanços, o controle das moscas-das-frutas continua sendo um desafio fundamental. A detecção automática de insetos-praga tem sido um objetivo buscado há décadas, desde os anos 1950, mas ainda não alcançou plenamente a maturidade [5].

Na literatura, as características obtidas no espectro de frequência têm sido amplamente utilizadas no reconhecimento dos insetos. No entanto, em algumas amostras de sinal, o espectro de frequência apresenta uma magnitude do segundo harmônico maior do que a da frequência fundamental, o que pode resultar em erros na identificação da frequência fundamental [12].

Como alternativa ao uso da FFT propomos o uso da função de Autocorrelação como técnica alternativa para estimar a frequência fundamental. Para avaliar essa possibilidade, desenvolvemos um sistema de reconhecimento de moscas-das-frutas *A. fraterculus* e *C. capitata*, no qual comparamos o uso das características da frequência fundamental estimada pela Autocorrelação, FFT e espectro de frequência. Optamos por utilizar essas espécies de moscas-das-frutas devido à sua grande importância na fruticultura nacional e à falta de estudos que garantam a possibilidade de identificá-las utilizando sinais bioacústicos.

II. METODOLOGIA

Na Figura 1 é apresentado o diagrama com o funcionamento da armadilha inteligente para o reconhecimento de moscas-das-frutas.

A armadilha inteligente consiste em um dispositivo capaz de capturar e processar o sinal bioacústico gerado pelo batimento de asas das moscas-das-frutas, identificando a espécie. O processo de reconhecimento inicia-se com a entrada do inseto na armadilha, passando pelo sensor optoeletrônico localizado no cone de entrada. O sinal capturado, que inclui tanto o ruído de fundo quanto os sinais gerados pelo batimento de asas dos insetos, é submetido à análise pelo detector de passagem,

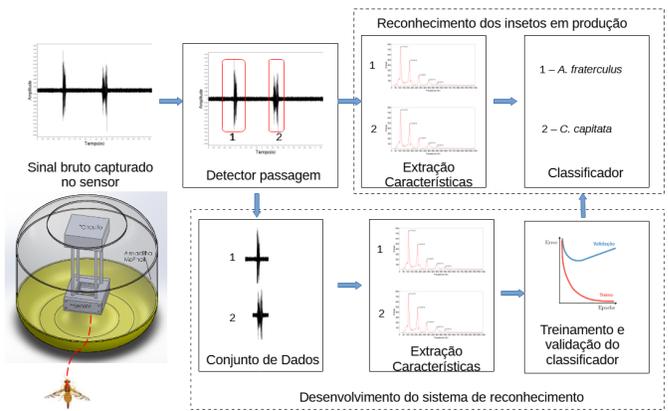


Fig. 1. Diagrama em blocos com o funcionamento da armadilha inteligente para o reconhecimento de moscas-das-frutas.

que segmenta as amostras de sinal contendo a passagem dos insetos pelo sensor.

Para o desenvolvimento do modelo de reconhecimento, as amostras de sinais segmentadas são organizadas em um conjunto de dados. Em seguida, são extraídas as características dessas amostras, sendo realizado o treinamento e a validação do classificador.

A aplicação do modelo de reconhecimento na armadilha inicia-se com a extração das características da amostra de sinal segmentada. Essas características são então aplicadas ao modelo para identificar a espécie correspondente.

A. Sensor optoeletrônico

O sensor optoeletrônico (Figura 2) é um dispositivo capaz de converter as variações de luz em um sinal elétrico proporcional. Sua utilização em substituição aos microfones apresenta vantagens significativas, como a capacidade de capturar o sinal de um inseto por vez e sua imunidade a ruídos sonoros do ambiente. Isso o torna adequado para ser empregado em armadilhas inteligentes [7]. No presente trabalho, empregamos um sensor específico desenvolvido em [12].

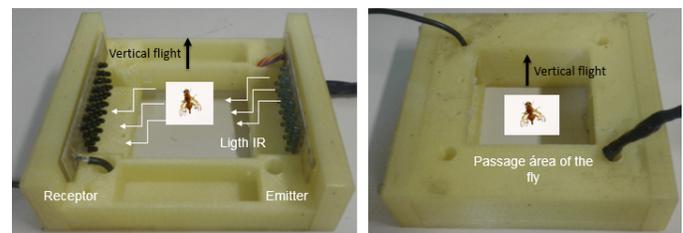


Fig. 2. Sensor optoeletrônico desenvolvido em [12].

Esse sensor é composto por um emissor e um receptor de luz infravermelha, juntamente com um circuito de condicionamento de sinais. Quando um inseto atravessa voando o sensor, o abrir e fechar das asas causa flutuações na luz, que são correspondentes ao sinal bioacústico do batimento de asas. Essas flutuações são então convertidas em um sinal elétrico que passa por um processo de filtragem, visando

eliminar ruídos e separar o sinal de batimento de asas do sinal bruto captado pelo sensor. Em seguida, o sinal condicionado é digitalizado para fins de reconhecimento.

B. Conjunto de dados

Para criar o conjunto de dados, utilizamos pupas das moscas-das-frutas *A. fraterculus* e *C. capitata* que estavam prestes a emergir. Essa escolha deve-se à facilidade de manipulação e ao fato de que as moscas recém-emergidas já apresentam características morfológicas semelhantes aos insetos adultos. As gravações foram feitas colocando as pupas em um cano de PVC de 10 por 10 cm, com o sensor optoeletrônico posicionado sobre o cano. O interior do cano foi pulverizado com talco branco para evitar que as moscas subissem caminhando pelo cano. Todos os experimentos foram conduzidos em condições de iluminação natural e temperatura ambiente de 28 °C. A Figura 3 ilustra a montagem do sensor optoeletrônico com o cano de PVC no insetário durante as gravações.



Fig. 3. Insetário com o sensor posicionado para as gravações.

A gravação do sinal foi feita utilizando a placa de som integrada de um Notebook, conectando a saída do sensor à entrada de microfone. O sinal foi gravado com taxa de amostragem de 192 kHz e resolução de 16 bits utilizando o *software* Audacity versão 3.3.0.

Após a gravação, as amostras de sinal foram segmentadas por meio da função “*Label Sound*” do Audacity, que permite marcar rótulos na faixa de sinal quando o valor RMS (*Root Mean Square*) de janelas deslizantes ultrapassa um determinado limiar. O limiar foi ajustado empiricamente para cada faixa de sinal, visando obter o melhor aproveitamento dos sinais de passagem. Com base nos rótulos marcados, realizamos a segmentação do sinal para formar o conjunto de dados.

No total, foram gravadas 17 horas de sinal para cada espécie de mosca, resultando em 443 amostras para cada espécie, totalizando 886 amostras.

C. Extração de características

A extração de características começa com a aplicação de uma função de janelamento à amostra de sinal segmentada. Essa técnica é utilizada para suavizar a descontinuidade abrupta do sinal causada pela segmentação, a qual

pode gerar vazamento espectral e dificultar a determinação das frequências presentes no sinal. Optamos por utilizar a janela Blackman-Harris de 4 termos como função de janelamento, devido ao seu baixo vazamento espectral, largura de banda razoável e erro de amplitude controlado. A janela de Blackman-Harris de 4 termos é definida por:

$$z = \frac{2\pi \cdot n}{N}, \quad n = 0 \dots N - 1 \quad (1)$$

$$w_j = a_0 - a_1 \cos(z) + a_2 \cos(2z) - a_3 \cos(3z) \quad (2)$$

onde N é o comprimento da janela, $a_0 = 0,35875$, $a_1 = 0,48829$, $a_2 = 0,14128$ e $a_3 = 0,01168$ [13].

Após a aplicação da função de janelamento, realizamos o processo de expansão do sinal para o tempo de 1 segundo utilizando a técnica de *padding*. Essa técnica consiste em inserir valores zero na amostra até que ela atinja a duração desejada. A expansão do sinal visa padronizar o tamanho de todas as amostras, facilitando a aplicação de técnicas de extração de características que utilizam o espectro de frequência.

Utilizamos duas técnicas de extração de características: a função de Autocorrelação e a Transformada Rápida de Fourier (FFT).

A transformação do sinal do domínio do tempo para o domínio da frequência é uma técnica amplamente utilizada no processamento digital de sinais para a extração de características. Essa transformação permite analisar o sinal em termos das frequências que o compõem, possibilitando a separação das frequências de interesse. Além disso, é vantajoso que sinais com diferentes comprimentos no domínio do tempo possam ser transformados para o domínio da frequência com um espectro de frequência de mesmo comprimento, facilitando a aplicação de técnicas de extração de características e aprendizado de máquina [14].

A Transformada Rápida de Fourier (FFT) é uma das técnicas mais utilizadas para obter o espectro de frequência. Ela opera decompondo um sinal de domínio de tempo com N valores em N sinais de domínio de tempo, cada um composto por um único valor. Em seguida, são calculados os espectros de frequência correspondentes a esses N sinais no domínio do tempo. Por fim, os espectros N são sintetizados em um único espectro de frequência [14].

Como alternativa ao uso da FFT, propomos o uso da função de Autocorrelação. A Autocorrelação é frequentemente utilizada para detectar a periodicidade em sinais, permitindo estimar o *pitch* (frequência fundamental) em sinais ruidosos. O *pitch* refere-se à percepção da altura de um som e é uma característica utilizada em sistemas de reconhecimento de fala e locutor. A função de Autocorrelação realiza a correlação do sinal com ele mesmo, destacando as componentes periódicas do sinal. O primeiro pico observado no resultado da Autocorrelação indica o período da onda e, conseqüentemente, a frequência fundamental. A função de Autocorrelação é expressa por:

$$r_{xx}(l) = \sum_{i=1}^{Nw} x(i+l)x(i) \quad (3)$$

onde $x(i)$ representa o sinal ao qual a função é aplicada e l é o atraso para realizar a convolução do sinal [15].

Por meio da aplicação das técnicas de FFT e Autocorrelação, estimamos a frequência fundamental do sinal como características reduzidas. Além disso, utilizamos o espectro de frequência completo obtido pela FFT, no qual temos, além da frequência fundamental, todas as outras frequências que compõem o sinal, como características na etapa de classificação

D. Classificador

Para realizar o treinamento e a avaliação dos modelos de classificação, dividimos as amostras em dois conjuntos: treino e teste. O conjunto de treino foi composto por 710 amostras, utilizadas para realizar o treinamento, a validação e a seleção dos modelos. Já o conjunto de teste foi composto por 176 amostras, utilizado para a avaliação final dos modelos selecionados durante o treinamento e a validação. As amostras foram escolhidas aleatoriamente, mantendo o balanceamento das classes.

O ajuste de hiperparâmetros e a seleção dos modelos foram realizados utilizando o método de validação cruzada *K-Fold*, com $K = 10$. Esse método envolve a divisão aleatória do conjunto de treinamento em k segmentos sem substituição, em que $k - 1$ segmentos são utilizados para treinar o modelo e um segmento é reservado para a avaliação de desempenho. Esse processo é repetido k vezes para obter k modelos e estimativas de desempenho. Em seguida, é calculada a média do desempenho dos modelos com base nos diferentes segmentos de teste independentes. Esse método permite obter uma estimativa de desempenho mais robusta e menos sensível à partição específica realizada para treinamento e validação [16].

Os modelos selecionados foram treinados com os hiperparâmetros ajustados utilizando o conjunto de treinamento completo. Em seguida, esses modelos foram avaliados utilizando o conjunto de testes para verificar o seu poder de generalização. Essa avaliação permite verificar como os modelos se comportam com dados novos, simulando assim situações reais de uso, como em armadilhas inteligentes.

Optamos por avaliar uma variedade de técnicas de Aprendizado de Máquina com diferentes vieses de treinamento. As técnicas avaliadas incluíram Regressão Logística (LR), Máquina de Vetores de Suporte (SVM), Árvore de Decisão (DT), Rede Neural *Multilayer Perceptron* (MLP), *Random Forest* (RF) e *Extreme Gradient Boosting* (XGB). Essa avaliação nos permitiu determinar qual viés de treinamento se ajusta melhor aos dados.

Como métricas de avaliação, optamos pelo uso da sensibilidade por espécie de mosca e da acurácia do modelo. A sensibilidade mede a capacidade do modelo de classificação em prever corretamente os insetos em relação à sua espécie. É calculada utilizando a seguinte equação:

$$\text{Sensibilidade} = \frac{TP}{TP + FN} \quad (4)$$

onde TP representa os verdadeiros positivos (amostras corretamente classificadas na sua espécie) e FN representa os

falsos negativos (amostras classificadas na espécie errada) [16].

No contexto do nosso estudo, a sensibilidade é uma métrica importante por ser desejável reconhecer todas as moscas-das-frutas de interesse, mesmo que ocorram falsas detecções.

A acurácia, por sua vez, é uma medida geral de desempenho do modelo e representa a proporção de amostras corretamente classificadas em relação ao total de amostras. É calculada pela seguinte equação:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

onde TP , TN , FP e FN representam, respectivamente, verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos [16].

III. RESULTADOS

A apresentação dos resultados foi dividida em duas partes: conjunto de dados e sistema de reconhecimento.

A. Conjunto de dados

A análise do conjunto de dados foi realizada apenas sobre o subconjunto utilizado no treinamento. Devido às características dos dados, sinais no tempo, realizamos análises sobre a duração dos sinais e, no domínio da frequência, sobre a frequência fundamental obtida por meio da FFT e Autocorrelação.

Optamos por utilizar a frequência fundamental para a análise dos dados, pois utilizar o espectro completo resultaria em uma alta dimensionalidade (com centenas de valores por amostra), sendo que o componente principal do espectro é a frequência fundamental.

O histograma mostrado na Figura 4 revela que as amostras da espécie *C. capitata* possuem uma duração maior em comparação às amostras da espécie *A. fraterculus*. De fato, 71% das amostras de *A. fraterculus* têm uma duração menor do que a amostra de *C. capitata* com a menor duração. Essa diferença de duração pode indicar que algumas moscas da espécie *A. fraterculus* possam não ter passado pelo sensor em um único voo, podendo ter ocorrido pousos no sensor durante o processo. Essa característica do conjunto de dados pode representar um desafio na classificação da espécie *A. fraterculus*, pois podem existir diferenças entre os sinais das moscas que passaram em um único voo, daquelas que pousaram no sensor. Além disso, o tempo menor de duração das amostras de *A. fraterculus* pode dificultar a extração de características representativas.

A Figura 5 apresenta a densidade de distribuição da frequência fundamental obtida pela Autocorrelação (esquerda) e pela FFT (direita). Podemos observar que as distribuições se sobrepõem, o que torna a classificação com base nessas características desafiadoras. Além disso, ambas as técnicas apresentam erros na determinação da frequência fundamental. Em alguns casos, a Autocorrelação estima o valor como a metade da frequência correta, enquanto a FFT apresenta o dobro do valor correto. Esses erros adicionais podem levar

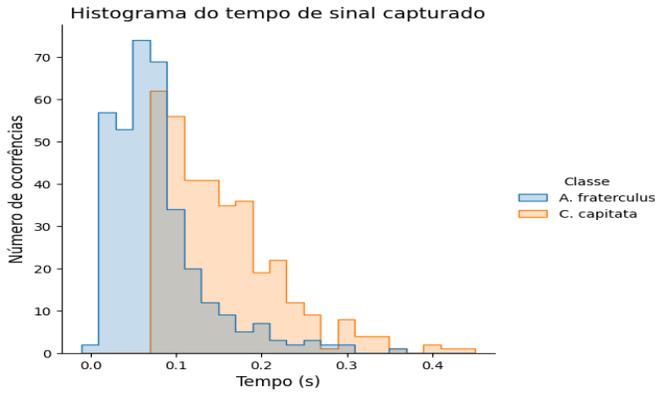


Fig. 4. Histograma com o tempo de duração dos sinais das amostras de batimento de asas.

a confusões na classificação entre as espécies *C. capitata* e *A. fraterculus*.

Outro ponto importante é que os erros não ocorrem nas mesmas amostras quando utilizamos a FFT e a Autocorrelação. Isso sugere que o uso conjunto dessas técnicas pode complementar e aprimorar a extração de características, resultando em modelos com melhor desempenho de classificação.

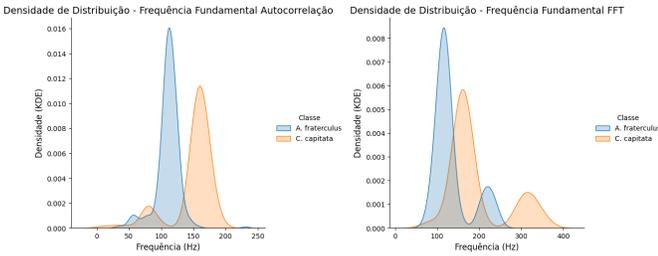


Fig. 5. Gráfico com a densidade de distribuição das frequências fundamentais obtidas para as duas moscas. Cada gráfico corresponde a frequência fundamental obtida com a FFT e com a Autocorrelação.

B. Sistema de reconhecimento

Utilizando as amostras de sinais do conjunto de treino pré-processadas (janeladas e expandidas para o tempo de 1 segundo), foram extraídas as seguintes características: a frequência fundamental obtida utilizando as técnicas de FFT (F0-FFT) e Autocorrelação (F0-AUT), além do espectro de frequência (0 Hz até 1000 Hz) obtido por meio da técnica de FFT (espectro).

A Tabela I apresenta a sensibilidade média obtida pelos modelos de classificação (Regressão Logística - LR, Máquina de Vetores de Suporte - SVM, Árvore de Decisão - DT, Rede Neural Multilayer Perceptron - MLP, *Random Forest* - RF e *Extreme Gradient Boosting* - XGB) treinados utilizando o método de validação cruzada *K-Folds*, com $k = 10$. Para as características F0-AUT, F0-FFT e F0-FFT/F0-AUT, os modelos gerados com RF (profundidade de árvore limitada em 5) obtiveram os melhores resultados. Por outro lado, ao utilizar o espectro de frequência, o melhor resultado foi obtido com o uso da SVM utilizando kernel de função de base radial.

TABELA I

RESULTADO PERCENTUAL DA MÉDIA DA SENSIBILIDADE POR MOSCA OBTIDO COM O MÉTODO DE VALIDAÇÃO *K-Folds*. O MODELO QUE APRESENTOU O MELHOR DESEMPENHO EM CADA CONJUNTO DE CARACTERÍSTICA FOI DESTACADO EM NEGRITO.

Conj. de Caract.	Classe	Modelos (sensibilidade)					
		LR	SVM	DT	MLP	RF	XGB
F0-AUT	CC	100	100	95,9	30,6	96,4	95,2
	AF	1,1	1,1	91,6	65,5	92,0	93,0
F0-FFT	CC	71,9	91,2	93,2	74,0	92,7	92,1
	AF	82,2	95,8	93,2	38,3	93,6	92,1
F0-AUT	CC	86,5	70,0	95,3	61,8	96,4	95,2
F0-FFT	AF	80,5	81,1	94,3	47,9	95,6	94,1
Espectro	CC	96,1	96,3	91,7	94,6	94,3	93,3
	AF	97,1	97,8	90,5	96,0	97,8	96,1

Conjunto de Características: frequência fundamental com Autocorrelação (F0-AUT), frequência fundamental com FFT (F0-FFT), frequência fundamental com FFT e Autocorrelação (F0-FFT e F0-AUT) e o espectro de frequência com FFT (Espectro)

Classes: *C. capitata* (CC) e *A. fraterculus* (AF)

Modelos: Regressão Logística (LR), Máquina de Vetores de Suporte (SVM), Árvore de Decisão (DT), Rede Neural Multilayer Perceptron (MLP), *Random Forest* (RF) e *Extreme Gradient Boosting* (XGB)

Analisando os resultados da Tabela I, podemos observar que, ao utilizar um número reduzido de características no modelo, seja apenas uma característica (F0-AUT ou F0-FFT) ou duas características (F0-AUT e F0-FFT), os modelos obtidos com a técnica *Random Forest* (RF) apresentaram o melhor desempenho. Outro aspecto importante é que o uso da frequência fundamental obtida por meio de duas técnicas diferentes (FFT e Autocorrelação) resultou em um desempenho superior (acurácia de 96%) em comparação com o uso de apenas uma técnica (F0-AUT: acurácia de 94,2% e F0-FFT: acurácia de 93,2%).

Também foi observado que a mosca *A. fraterculus* teve uma sensibilidade menor em relação à mosca *C. capitata*, o que indica que o tempo de duração dos sinais pode influenciar na qualidade do sistema de extração de características e, conseqüentemente, no desempenho dos modelos. Por fim, vale ressaltar o desempenho dos modelos obtidos com a técnica DT (acurácia de 94,8%), que, apesar de ser um modelo simples, apresentou um desempenho similar aos modelos obtidos com RF. Isso sugere que a técnica de Árvore de Decisão pode ser aplicada em dispositivos de baixo poder computacional, com restrições de memória e alimentados por bateria, sem uma perda considerável de desempenho.

Utilizando o espectro de frequência, que inclui além da frequência fundamental todas as outras frequências presentes no sinal, o modelo treinado com a técnica de Máquina de Vetores de Suporte (SVM) obteve o melhor desempenho (acurácia de 97%). No geral, ao utilizar o espectro de frequência, a sensibilidade da *A. fraterculus* apresentou um desempenho superior em comparação com a *C. capitata*. Isso indica que o uso de características mais representativas podem auxiliar no caso de sinais com um tempo de duração menor.

Em comparação com os modelos que utilizaram um número reduzido de características, foi observado que, para a mosca *C. capitata*, o desempenho foi semelhante, enquanto para a mosca

A. fraterculus, o desempenho foi superior. Isso ratificar que o uso de características mais representativas é mais vantajoso quando o tempo de duração do sinal é curto, e que um modelo com menos características pode apresentar desempenho comparável a modelos que utilizem características mais representativas. Além disso, a obtenção da frequência fundamental e suas harmônicas pode ser utilizada como técnica para reduzir a dimensão do espectro de frequência.

Os modelos que obtiveram o melhor desempenho por conjunto de características foram testados sobre o conjunto de testes para avaliar o seu poder de generalização. Os resultados obtidos são apresentados na Tabela II.

TABELA II

RESULTADO DOS MODELOS SELECIONADOS POR CONJUNTO DE CARACTERÍSTICAS SOBRE O CONJUNTO DE TESTE. O RESULTADO CORRESPONDE AOS VALORES PERCENTUAIS DA SENSIBILIDADE DE CADA CLASSE E A DA ACURÁCIA DOS MODELOS.

Conjunto de Características	Modelo	Sensibilidade		Acurácia
		CC	AF	
F0-AUT	RF	92,1	93,2	92,6
F0-FFT	RF	92,1	92,1	92,1
F0-AUT/F0-FFT	RF	95,5	94,3	94,9
Espectro	SVM	96,7	96,7	96,7

Conjunto de Características: frequência fundamental com Autocorrelação (F0-AUT), frequência fundamental com FFT (F0-FFT), frequência fundamental com FFT e Autocorrelação (F0-FFT e F0-AUT) e o espectro de frequência com FFT (Espectro)

Classes: *C. capitata* (CC) e *A. fraterculus* (AF)

Modelos: Máquina de Vetores de Suporte e *Random Forest* (RF)

Podemos observar que os modelos obtiveram desempenhos semelhantes aos da validação (Tabela I), indicando que os modelos têm capacidade de generalização. Os resultados ainda ratificam as conclusões obtidas durante a validação, de que o uso da Autocorrelação em conjunto com a FFT para obtenção da frequência fundamental melhora o desempenho dos modelos, e que o uso dessas duas características tem um desempenho próximo ao obtido com o espectro de frequência (diferença de 1,8%).

IV. CONCLUSÃO

Neste trabalho, propomos utilizar a função de Autocorrelação como uma técnica de extração de características do sinal bioacústico gerado pelo batimento de asas das moscas-das-frutas, visando reconhecer as espécies utilizando Aprendizado de Máquina.

Nossos resultados comprovam a viabilidade de utilizar o sinal de batimento de asas para distinguir entre as espécies *C. capitata* e *A. fraterculus*. Além disso, constatamos que o uso combinado da frequência fundamental estimada pela FFT e pela Autocorrelação melhora o desempenho dos modelos de classificação em comparação com o uso de apenas uma dessas técnicas. Também foi demonstrado que o modelo que utiliza a frequência fundamental estimada por ambas as técnicas (acurácia de 96% com RF) apresenta resultados comparáveis ao modelo que utiliza o espectro de frequência completo (acurácia de 97% com SVM).

Observamos que o modelo utilizando Árvore de Decisão (DT) alcançou uma acurácia de 94,8% ao utilizar a frequência

fundamental estimada com ambas as técnicas. Isso indica que o uso da Autocorrelação possibilita que classificadores simples, como a DT, apresentem um desempenho comparável aos classificadores mais complexos que utilizam o espectro de frequência completo. A utilização de classificadores simples possibilita a incorporação do sistema de reconhecimento de moscas-das-frutas em armadilhas inteligentes, empregando *hardwares* de baixo custo, com limitações de poder computacional e capacidade de memória.

Concluímos que a Autocorrelação é uma técnica viável e eficaz para ser utilizada no reconhecimento das espécies de moscas-das-frutas, aprimorando o desempenho dos modelos de classificação e permitindo a implementação em dispositivos com recursos limitados.

REFERÊNCIAS

- [1] Ministério da Agricultura, Pecuária e Abastecimento. PLANO NACIONAL DE DESENVOLVIMENTO DA FRUTICULTURA. acessado em maio de 2023. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/noticias/mapa-lanca-plano-de-fruticultura-em-parceria-com-o-setor-privado>.
- [2] DIAS, N. d. S. et al. Moscas-das-frutas (Diptera: Tephritidae) e plantas hospedeiras em municípios do estado do Ceará. [S.l.]: Fortaleza: Embrapa Agroindústria Tropical., 2022.
- [3] PARANHOS, B. J.; NAVA, D. E.; MALAVASI, A. Biological control of fruit flies in Brazil. Pesquisa Agropecuária Brasileira, [S.l.], v.54, 2019.
- [4] NAVA, D. E.; BOTTON, M. Bioecologia e controle de *Anastrepha fraterculus* e *Ceratitidis capitata* em pessegueiro. [S.l.]: Pelotas: Embrapa Clima Temperado., 2010.
- [5] HASSALL, Kirsty L. et al. Resolving the identification of weak-flying insects during flight: a coupling between rigorous data processing and biology. Agricultural and Forest Entomology, v. 23, n. 4, p. 489, 2021.
- [6] POTAMITIS, Ilyas; GANCHEV, Todor; FAKOTAKIS, Nikos. Automatic acoustic identification of insects inspired by the speaker recognition paradigm. In: INTERSPEECH. 2006.
- [7] POTAMITIS, Ilyas; RIGAKIS, Iraklis. Measuring the fundamental frequency and the harmonic properties of the wingbeat of a large number of mosquitoes in flight using 2D optoacoustic sensors. Applied Acoustics, v. 109, p. 54-60, 2016.
- [8] GONZALEZ-PÉREZ, María I. et al. A novel optical sensor system for the automatic classification of mosquitoes by genus and sex with high levels of accuracy. Parasites and vectors, v. 15, n. 1, p. 1-11, 2022.
- [9] VASCONCELOS, Dinarte; NUNES, Nuno Jardim; GOMES, João. An annotated dataset of bioacoustic sensing and features of mosquitoes. Scientific Data, v. 7, n. 1, p. 382, 2020.
- [10] POTAMITIS, Ilyas; RIGAKIS, Iraklis; FYSARAKIS, Konstantinos. Insect biometrics: Optoacoustic signal processing and its applications to remote monitoring of McPhail type traps. PloS one, v. 10, n. 11, p. e0140474, 2015.
- [11] POTAMITIS, Ilyas; RIGAKIS, Iraklis; TATLAS, Nicolaos-Alexandros. Automated surveillance of fruit flies. Sensors, v. 17, n. 1, p. 110, 2017.
- [12] SANDRINI MORAES, Fabiano; EDSON NAVA, Dori; SCHEUNEMANN, Tiago; SANTOS da ROSA, Vagner. Development of an optoelectronic sensor for detecting and classifying fruit fly (Diptera: Tephritidae) for use in real-time intelligent traps. Sensors, v. 19, n. 5, p. 1254, 2019.
- [13] HEINZEL, Gerhard; RÜDIGER, Albrecht; SCHILLING, Roland. Spectrum and spectral density estimation by the Discrete Fourier transform (DFT), including a comprehensive list of window functions and some new at-top windows. 2002.
- [14] PROAKIS, John G. Digital signal processing: principles, algorithms, and applications, 4/E. Pearson Education India, 2007.
- [15] GERHARD, David et al. Pitch extraction and fundamental frequency: History and current techniques. Regina, SK, Canada: Department of Computer Science, University of Regina, 2003.
- [16] RASCHKA, Sebastian; MIRJALILI, Vahid. Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2. Packt Publishing Ltd, 2019.