



APRENDIZAGEM DE MÁQUINA PARA IDENTIFICAÇÃO DE PLANTAS DE SOJA SOB ATAQUE DE INSETOS USANDO DADOS HIPERESPECTRAIS

MACHINE LEARNING TO IDENTIFY SOYBEAN PLANTS UNDER INSECT ATTACK USING HYPERSPECTRAL DATA.

Daniel Veras Correa¹, Ana Paula Marques Ramos¹, Lucas Prado Osco¹, Lúcio André de Castro Jorge²

¹Universidade do Oeste Paulista – UNOESTE, Presidente Prudente, SP, ²Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA.

E-mail: danielveras248@gmail.com

RESUMO – A integração entre as áreas de sensoriamento remoto e *machine learning* tem permitido um avanço na forma de mapeamento de campos agrícolas e monitoramento de culturas. Este trabalho investiga a capacidade de algoritmos de aprendizagem de máquina em classificar plantas de soja sob ataque de insetos, utilizando medidas de espectroscopia de refletância coletadas ao nível foliar. Para tanto, desenvolveu-se testes com diferentes algoritmos utilizando um conjunto de 991 curvas espectrais referentes à planta de soja saudável e sob ataque de pragas, coletadas em oito dias consecutivos. Essas curvas foram medidas pela equipe da EMBRAPA, usando um espectrorradiômetro portátil, que registra no intervalo de 350 a 2500 nm. Tais curvas foram, inicialmente, pré-processadas para a remoção das regiões de absorção atmosférica pelo vapor d'água, e em seguida subdividida em conjunto de treino, validação e teste dos algoritmos de aprendizagem de máquina. Utilizou-se o interpretador *Google Collabs* e os algoritmos foram inscritos em linguagem Python, utilizando bibliotecas, como a *Sklearn*. Dentre os algoritmos utilizados, tem-se Random Forest, Decision Tree, Support Vector Machine, Logistic Regression e Extra-Tree. O Extra-tree tem melhor desempenho (F1-score = 80,40%; precision = 81%; recall = 80%) na tarefa proposta. Conclui-se que é possível processar medidas de espectroscopia de refletância com algoritmos de aprendizagem de máquina para se monitorar o ataque por insetos em plantas de soja. Recomenda-se que a abordagem aplicada seja testada em outras culturas.

Palavras-chave: medidas de refletância; aprendizagem de máquina; agricultura de precisão.

ABSTRACT – The integration between the areas of remote sensing and machine learning has allowed an advance in the way of mapping agricultural fields and monitoring crops. This work investigates the ability of machine learning algorithms to classify soybean plants under insect attack, using reflectance spectroscopy measurements collected at the leaf level. To this end, tests were developed with different algorithms using a set of 991 spectral curves referring to healthy soybean plants under attack by pests, collected in

eight consecutive days. These curves were measured by the EMBRAPA team, using a portable spectroradiometer, which records in the range of 350 to 2500 nm. Such curves were, initially, pre-processed to remove the regions of atmospheric absorption by water vapor, and then subdivided into a set of training, validation and testing of the machine learning algorithms. The Google Collabs interpreter was used and the algorithms were written in Python language, using libraries such as Skit Sklearn. Among the algorithms used, there are Random Forest, Decision Tree, Support Vector Machine, Logistic Regression and Extra-Tree. The Extra-tree has better performance (F1-score = 80.40%; precision = 81%; recall = 80%) in the proposed task. It is concluded that it is possible to process reflectance spectroscopy measurements with machine learning algorithms to monitor insect attack on soybean plants. It is recommended that the applied approach be tested in other cultures.

Keywords: remote sensing; machine learning; hyperspectral.

1. INTRODUÇÃO

A produção de soja, uma leguminosa de origem chinesa, iniciou-se no Brasil na década de 1980, e, no contexto mundial, o Brasil ocupa a 2ª posição na produção atualmente, atrás somente dos EUA (EMBRAPA, 2022). Essa cultura requer um contínuo monitoramento quanto, por exemplo, ao controle de pragas, visando a manutenção de sua produtividade. Dentre estas pragas estão a lagarta *Spodoptera frugiperda* e os percevejos *Dichelops melacanthus* (VESSONI, 2020), e, no decorrer dos anos, diferentes formas de controle de pragas em culturas vêm sendo implementadas.

Tradicionalmente, a forma de monitoramento de lavouras é por meio de inspeção em campo, em que técnicos utilizam de observação visual de plantas e de coleta de amostras de folhas para a condução de análises laboratoriais, caracterizando uma abordagem onerosa (MIN;LEE, 2005). Novas abordagens baseadas no uso de geotecnologias vêm sendo implementadas, visando atender à demanda da por uma produção cada vez maior, com menor custo e tempo (EMBRAPA, 2022). O uso de dados de sensoriamento remoto, tanto imagens quanto curvas espectrais, têm sido uma dessas abordagens que possibilitam mapear campos agrícolas, ou suas características, seja na escala de talhões, planta, ou mesmo, ao nível foliar (WESR *et al.*, 2010; FURLANETTO *et al.* 2017).

O sensoriamento remoto é uma ciência que possibilita a aquisição de dados sem que haja o contato físico entre o sensor e o alvo (ex.: cultura de soja) (Jensen, 2014). Estes dados, imagens ou curvas espectrais, podem corresponder a dados multiespectrais, quando

dezenas de faixas espectrais são registradas pelo sensor, ou hiperespectrais, quando do registro de centenas ou milhares de bandas, e representam a resposta que o alvo possui ao interagir com a radiação eletromagnética, sendo este comportamento influenciado, por exemplo, pelos constituintes físicos, químicos e biológicos do alvo (JENSEN, 2014). Os sensores hiperespectrais, por operarem em regiões espectrais contíguas e estreitas, possibilitam mapear a assinatura espectral ou a resposta espectral do alvo com grande nível de detalhe (JENSEN, 2014), e com isto se pode extrair informações sobre o alvo, como o seu estado de senescência, detecção de estresse, deficiência de macro ou micronutrientes ou mesmo se o alvo se encontra sob o ataque de insetos ou pragas (JENSEN, 2014; OSCO *et al.* 2020).

Nos últimos anos, tem-se observado uma considerável integração entre as áreas de sensoriamento remoto e aprendizagem de máquina em diferentes contextos de aplicação, incluindo o setor agrícola (OSCO *et al.* 2021). A aprendizagem de máquina é uma área da inteligência artificial, na qual algoritmos, paramétricos ou não paramétricos, aprendem a extrair padrões dos dados. A capacidade de identificação desses padrões ocorre a partir da análise hierárquica e não linear do conjunto amostral, tanto no caso supervisionado, quando se apresenta ao algoritmo exemplos de padrões que ele deve aprender a reconhecer, quanto no não supervisionado, quando o algoritmo aprende sozinho (GUZMÁN *et al.* 2018; FENG *et al.* 2019).

Neste sentido, o objetivo deste trabalho é avaliar a capacidade de algoritmos supervisionados de aprendizagem de máquina

em classificar plantas de soja sobre ataque de lagartas *Spodoptera frugiperda* e percevejos *Dichelops melacanthus* usando medidas hiperespectrais coletadas ao nível foliar destas plantas.

2. APRENDIZAGEM DE MÁQUINA

Machine Learning ou Aprendizado de máquina é um processo de automação de resoluções, no qual algoritmos de computador aprendem a extrair padrões dos dados (BURKOV, 2019; KELLEHER *et al.*, 2015).

Na aprendizagem de máquina, há a integração de várias áreas, como a matemática, a estatística e a ciência da computação, possibilitando a realização de análise preditivas poderosas de acordo com Muller e Guido (2017) e Aparicio *et al.* (2019). Alpaydin (2013) exemplifica que a partir de uma base de dados construída diariamente, como se faz no setor de vendas ou prestação de serviço, é possível aplicar aprendizagem de máquina e se extrair padrões nesta base que sejam úteis, por exemplo, para prever vendas ou lucros, ou melhorar processos. Isto denota que há muitos nichos de aplicação do machine learning, de modo que a matéria prima se resume a grandes volumes de dados. A ideia de se converter dados em informações permite a construção contínua, e com cada vez melhor desempenho, de sistemas que realizam predições, de forma a se tornar um sistema autônomo, podendo fazer mudanças e adequar suas previsões devidas às circunstâncias (SHALEV-SHWARTZ; BEN-DAVID, 2013).

2.1. Aprendizagem supervisionada

Em machine learning podem ser aplicados vários tipos de aprendizagem, entre elas está a aprendizagem supervisionada, a não supervisionada, a semi-supervisionada, e *reinforcement* (BURKOV, 2019). A aprendizagem de máquina supervisionada utiliza de amostras, dados de treinamento, para construir os modelos preditivos, tanto para atender à tarefa de classificação (predição de classes informacionais) ou de regressão (predição de valores) (KELLEHER *et al.*, 2015; MÜLLER; GUIDO, 2017). Alguns algoritmos que se enquadram na aprendizagem supervisionada e que são indicados para ambas as tarefas de classificação (separação de feições em classes) e regressão (previsão de valores) são *Decision Tree*, *Artificial Neural Network (ANN)*, *Random Forests*, *K-Nearest Neighbors* e *Support Vector Machine*. Cada um desses algoritmos tem

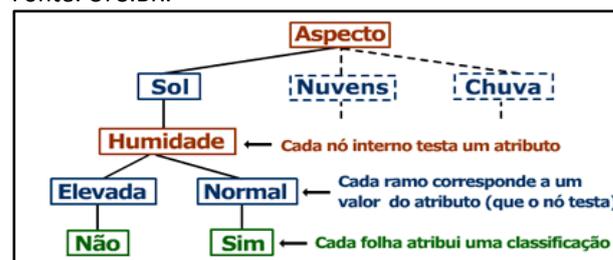
parâmetros específicos a ajustar na modelagem (MITCHELL, 1997; SILVA, 2021).

O algoritmo *Decision Tree* é um método de aprendizagem de máquina supervisionado e não-paramétrico. Seu princípio é determinar valores para uma função, a qual é representada por uma árvore de decisão (MITCHELL, 1997). Nesse tipo de árvore classificam-se as feições a partir do nó da raiz (início da árvore) até um nó da folha. Cada nó na árvore especifica um teste de um atributo da feição e cada ramificação descendente desse nó corresponde a um dos possíveis valores para esse atributo (Mitchell, 1997). A Figura 1 ilustra a arquitetura desse algoritmo. Algumas das vantagens de se trabalhar com árvores de decisão são que podem ser aplicadas em conjunto de dados contínuos ou discretos, não requerem suposição sobre a distribuição de frequência dos dados em cada classe, e a habilidade de manipular relações não lineares entre as feições e classes (MITCHELL, 1997).

Uma *Artificial Neural Network* ou Rede Neural Artificial (RNA) consiste em um método robusto para aproximar valores reais, discretos ou vetor de valores (discretos ou reais) para uma função (MITCHELL, 1997). Trata-se de uma abstração da rede neural biológica. Uma RNA é definida como uma complexa estrutura interligada por elementos de processamento denominados de neurônios. Se a RNA é composta por um único neurônio, ela é dita RNA Perceptron (Figura 2), sendo capaz de expressar somente decisões lineares. Neste tipo de rede, pode-se ter entradas, mas apenas uma única saída com um valor de 0 e 1 ou de -1 e 1. Em caso da RNA possuir dois ou mais neurônios, ela é dita RNA Multilayer (Figura 3), sendo capaz de lidar com os problemas não linearmente separáveis (MITCHELL, 1997).

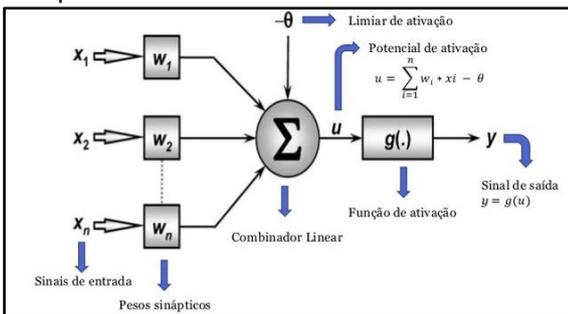
Figura 1. Exemplo de árvore de decisão para jogar tênis.

Fonte: UFS.BR.



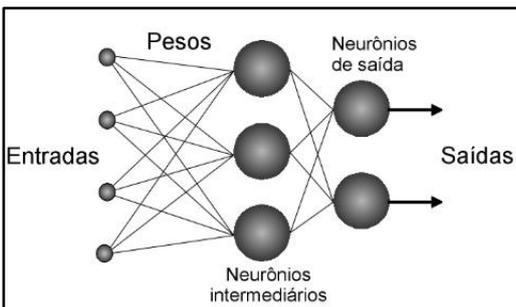
O princípio de funcionamento de uma RNA é ativar um ou mais neurônios (x_0, x_1, \dots, x_n) da rede, esses valores de entrada são multiplicados por pesos (w_0, w_1, \dots, w_n) que representam a importância de cada entrada em relação ao valor de saída desejado (y). O resultado da somatória das entradas ponderadas será somado ao limiar de ativação (θ), $u = \sum_{i=0}^n (w_i * x_i) - \theta$, e esse valor (u) é então repassado como argumento da função de ativação $g(u)$ que pode ser linear ou não linear, a qual terá como resultado a saída desejada (Mitchell, 1997). Em caso de uma RNA Multilayer, algoritmos como *backpropagation* (ou retropropagação) podem fazer uso do *gradient decente* (descida de gradiente) para ajustar os parâmetros (pesos) da RNA visando aperfeiçoar os resultados do modelo (Mitchell, 1997). A Figura 2 e 3 exemplifica uma RNA com 4 entradas e 2 saídas.

Figura 2. Exemplo de uma Rede Neural Artificial Perceptron



Fonte: Embarcados.

Figura 3. Exemplo de Multilayer sendo formado com 4 entradas e 2 saídas

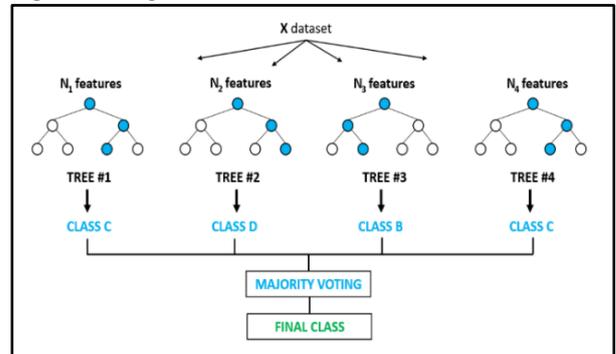


Fonte: Núcleo do Conhecimento.

O *Random Forests* é um algoritmo supervisionado baseado no princípio de árvores de decisão, porém que constrói um variado número de árvores na etapa de treinamento combinando-as para ser uma predição com maior acurácia e estável (HAN; KAMBER, 2006). Cada árvore depende dos valores de um vetor

aleatório amostrado de forma independente e com a mesma distribuição para todas as árvores da floresta. Durante a classificação, cada árvore vota e a classe mais popular é retornada (HAN; KAMBER, 2006). A Figura 4 mostra um exemplo de como esse algoritmo funciona.

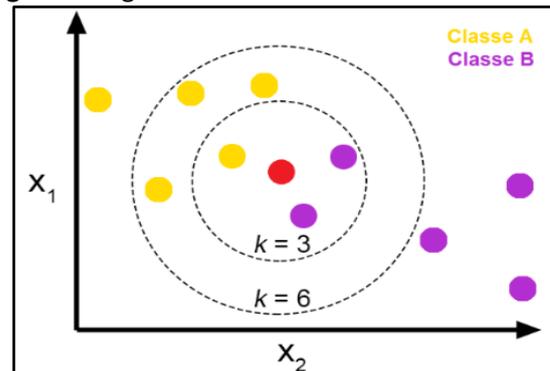
Figura 4. Algoritmo Random Forests



Fonte: Cibersistemas.

O algoritmo *K-Nearest Neighbors* é um método não paramétrico que assume que todas as feições (dados de treinamento) são pontos em um espaço n-dimensional. Os vizinhos mais próximos a uma instância são definidos a partir do cálculo de uma distância, tal como a distância euclidiana (Mitchell, 1997). Deve-se parametrizar um raio de busca (k) para executar o algoritmo, o qual é definido de modo iterativo muitas vezes. A Figura 5 ilustra a classificação das instâncias nas classes A e B para raios de busca.

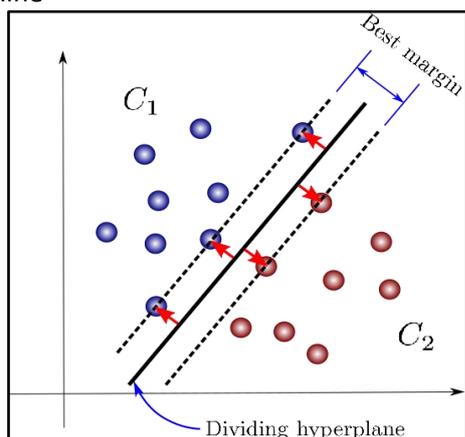
Figura 5. Algoritmo KNN



Fonte: Medium.

O algoritmo *Support Vector Machine* (SVM) realiza uma separação do espaço de atributos usando um hiperplano, o qual maximiza a margem entre as instâncias de diferentes classes ou valores (HAN; KAMBER, 2006). Esse hiperplano é encontrado usando o chamado 'vetor de suporte'. A Figura 6 ilustra um modelo do algoritmo SVM.

Figura 6. Modelo do algoritmo Support Vector Machine



Fonte: ResearchGate.

3. METODOLOGIA

3.1. Coleta dos dados e pré-processamento

As plantas de soja (*Glycine max*) utilizadas neste trabalho são cultivadas em laboratório pela Embrapa Recursos Genéticos e Biotecnologia em Brasília-DF, Brasil. Tais plantas foram submetidas ao ataque de dois tipos de insetos: a lagarta *Spodoptera frugiperda* e o percevejo *Dichelops melacanthus*, ambos criados, também, em laboratório pela EMBRAPA. Os insetos foram espalhados pelos vasos com plantas de soja. As plantas de soja foram denominadas de “saudáveis” quando não se fez a inserção dos insetos nos vasos de planta, e “danificadas” quando as plantas foram expostas aos insetos.

As medidas espectrais foram registradas durante um período de 08 dias, das 09:00 às 15:00 horas, sendo o dia 1, o primeiro dia de exposição da praga à planta, e o dia 8, o oitavo dia de exposição. O experimento resultou em 991 espectros coletados, sendo 465 para amostras de plantas de soja saudáveis, e 526 representando plantas de soja atacadas pelos insetos *Spodoptera frugiperda* ou *Dichelops melacanthus*.

As medidas hiperespectrais foram realizadas em laboratório, utilizando um espectrorradiômetro portátil ASD FieldSpec 3 (Analytical Spectral Devices Inc., Boulder, EUA). Esse aparelho registra comprimentos de onda de 350 a 1.000 nm, com resolução de 1,4 nm, e de 1.000 a 2.500 nm, com resolução espectral de 2 nm. Uma placa de Spectralon branca foi usada para calibrar o aparelho antes de realizar as medidas.

O pré-processamento dos dados consistiu em remover as regiões de absorção atmosféricas por vapor d'água atmosférico (Jensen, 2014), o que resultou em se trabalhar efetivamente com os modelos de aprendizado de máquina nas seguintes regiões espectrais: 390 a 1350 nm, 1440 a 1800 nm e 1980 a 2350 nm. Na sequência, os dados, que representam a radiância do alvo, foram convertidos em fator de refletância (ρ), conforme mostra a Equação (1). A refletância (ρ) é resultante da divisão da radiância do alvo (L_{alvo}) (ex.: planta de soja), pela irradiância solar, neste caso, simulada pela placa de Spectralon adotada como superfície de referência ($L_{\text{referência}}$), multiplicada por um fator de correção (K)

$$\rho_T = (L_{\text{alvo}} / L_{\text{referência}}) * K \quad (1)$$

3.2. Processamento por aprendizagem de máquina

Os dados pré-processados foram carregados para um ambiente computacional, o *Google Collabs*, e os códigos dos algoritmos escritos na linguagem de programação Python 3.9.9, utilizando a biblioteca para *machine learning*, o Scikit Sklearn. Os conjuntos de dados foram separados aleatoriamente em treino (70%), validação (10%) e teste (20%), sendo duas classes a serem aprendidas pelos algoritmos: 0 (Control) e 1 (Damaged).

Um conjunto de algoritmos foi testado, sendo os quais Logistic Regression (LR), Linear Discriminant Analysis (LDA), K-Neighbors (KNN), Decision Tree (CART), Random Forest (RF), Gaussian NB (NB), SVC (SVM), Gradient Boosting (GB), Multi Layer Perceptron (MLP), Extra Trees (ExT). O método de validação cruzada com 10 dobras, e com 10 repetições foi utilizado para o treinamento dos algoritmos. Esta estratégia de validação cruzada visa, no conjunto de treino e validação, separá-los em 10 partes, sendo 9 partes usadas para treinar os algoritmos e 1 para validar o aprendizado. Repete-se este processo 10 vezes, assim a variabilidades das 100 respostas podem ser analisadas, como em gráficos box-plot.

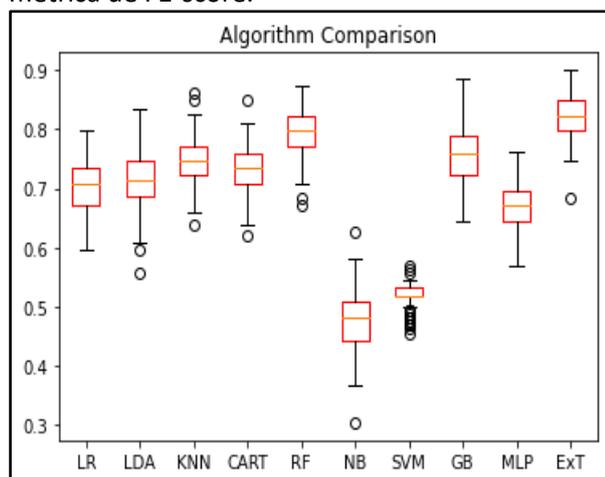
A análise de desempenho de cada algoritmo ocorreu pela construção da matriz de confusão. Desta matriz, fez-se a extração de métricas como o F-score, que é a média harmônica dos valores de precisão e recall, sendo indicada para avaliar o desempenho do modelo de forma generalizada.

4. RESULTADOS E DISCUSSÃO

A Figura 7 apresenta o desempenho dos algoritmos, e mostra que o ExT teve melhor desempenho na tarefa proposta, de forma que os resultados se sobressaíram sobre os outros algoritmos.

O desempenho do algoritmo ExT supera em 41,7% o algoritmo com desempenho mais inferior, o NB. O melhor desempenho do ExT pode estar relacionado com a característica do conjunto de dados, que é de alta dimensionalidade e redundância. Este algoritmo gera randomicamente árvores de decisão, e é realizada por cada uma a tarefa de classificação. Em seguida, adotando uma estratégia de votação, o algoritmo define a classe na qual o alvo deve pertencer, resultando em um modelo mais generalizado.

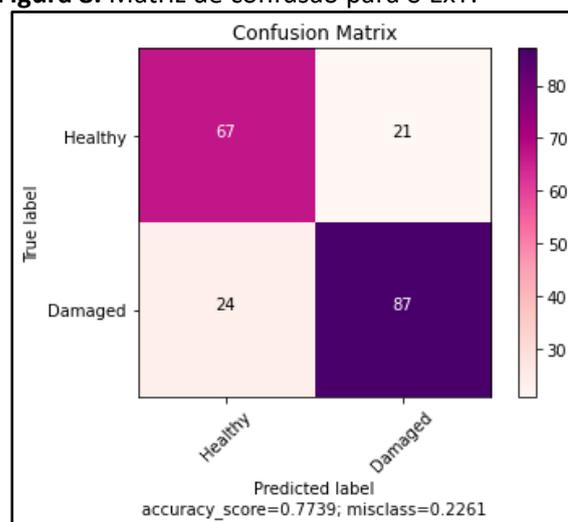
Figura 7. Comparação de Algoritmos pelo pela métrica de F1-score.



Fonte: De autoria própria.

A matriz de confusão do ExT (Figura 8) mostra os TP - verdadeiro positivo, os FP - falso positivo, os TN - verdadeiro negativo; e os FN - falso negativo. Por esta matriz, é possível analisar que o ExT apresentou dificuldade similar em confundir planta saudável com planta danificada (FN = 21%), quanto planta danificada com planta saudável (FP = 24%). Porém, o algoritmo teve 20% a mais de melhora, assim sendo capaz de reconhecer plantas sob ataque de insetos (TN = 87%) comparado à plantas saudáveis (TP = 67%). De modo que seu resultado ter sido maior (F1-score = 77%) dentro da métrica utilizada, assimilamos que o algoritmo ExT tem seu modelo mais adequado para esta função de separar plantas sob ataque de pragas e plantas saudáveis.

Figura 8. Matriz de confusão para o ExT.



Fonte: De autoria própria.

5. CONSIDERAÇÕES FINAIS

Este trabalho investigou o desempenho de um conjunto de algoritmos supervisionados de aprendizagem de máquina para classificar plantas de soja sob o ataque de lagartas *Spodoptera frugiperda* e de percevejos *Dichelops melacanthus* pela análise de dados hiperespectrais coletadas ao nível foliar. Conclui-se que o modelo de melhor performance foi construído pelo uso do algoritmo Extra Tree (F1-score = 77%).

O estudo de caso conduzido neste trabalho evidencia a possibilidade de se mapear a saúde de plantas por meio de sua resposta espectral. Recomenda-se que a abordagem avaliada seja reproduzida considerando outras culturas.

REFERÊNCIAS

- ALPAYDIN, E. **Introduction to Machine Learning** 3. ed. [S.l.]: The MIT Press, 2014.
- APARICIO, S.; APARICIO, J. T.; COSTA, C. J. Data Science and AI: trends analysis. *In: IBERIAN CONF ON INFORMATION SYSTEMS AND TECHNOLOGIES (CISTI)*. 14., 2019. **Anais [...]**. [S.l.]: IEEE, 2019.p. 1-6. DOI: <https://doi.org/10.23919/CISTI.2019.8760820>
- BISHOP, C. M. Pattern Recognition and Machine Learning. **Angewandte Chemie International Edition**, v. 6, n. 11, p. 951–952, 1967. DOI: <https://doi.org/10.1002/anie.196709511>

- BURKOV, A. **The Hundred-Page Machine Learning**. Quebec City, QC, Canada: Andriy Burkov, 2019.v.1
- EMBRAPA **Soja em números (safra 2020/21)**. Disponível em: <https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>. Acesso em 28 fev. 2022.
- FURLANETTO, R. H. *et al.* Potencial de utilização de sensores multiespectral e hiperespectral no estudo de diferentes alvos agrícolas. In: JORNADA ACADÊMICA DA EMBRAPA SOJA, 12., 2017, Londrina. **Anais [...]** Londrina: Embrapa Soja, 2017. p. 146-154., 2017.
- GAZZONI, D. L. *et al.* **Manejo de pragas da soja**. Embrapa Soja-Circular Técnica. (INFOTECA-E), 1988.
- GUZMÁN, S. M., PAZ, J. O., TAGERT, M. L. M., MERCER, A. E., POTE, J. W. 2018. **An integrated SVR and crop model to estimate the impacts of irrigation on daily groundwater levels**. *Agricultural Systems*, 159, 248–259. <https://doi.org/10.1016/j.agry.2017.01.017>
- HAN, J. D.; KAMBER, M. 2006. **Data Mining Concept and Techniques**. San Fransisco: Morgan Kauffman.
- HE, Li *et al.* **Improved remote sensing of leaf nitrogen concentration in winter wheat using multi-angular hyperspectral data**. *Remote Sensing of Environment*, v. 174, p. 122-133, 2016. <https://doi.org/10.1016/j.rse.2015.12.007>
- JENSEN, J.R., 2014. **Remote sensing of the environment: an earth resource perspective second edition**. Volume 1. Prentice Hall.
- Kelleher, J. D., Mac Namee, B., & D’Arcy, A. (2015). **Fundamentals of Machine Learning for Predictive Data Analytics**. MIT Press.
- LAZZAROTTO, J. J.; HIRAKURI, M. H. **Evolução e perspectivas de desempenho econômico associadas com a produção de soja nos contextos mundial brasileiro**. Londrina: Embrapa Soja, p. 46, 2010. (Embrapa Soja. Documentos, 319).
- MIN, M.; LEE, W. Determination of significant wavelengths and prediction of nitrogen content for citrus. **American Society of Agricultural Engineers**, v. 48, n. 2, p. 455-461, 2005. DOI: <https://doi.org/10.13031/2013.18308>
- MITCHELL, T. **Aprendizado de máquina**. Nova York: McGrawhill, 1997.
- MOREIRA, A. M. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa: UFV, 2011. 422 p.
- MÜLLER, A. C.;GUIDO, S. **Introduction to Machine Learning with Python**. O’Reilly Media, Inc. 2017. https://doi.org/10.1007/978-3-030-36826-5_10
- Osco, L. P. *et al.* A Machine Learning Framework to Predict Nutrient Content in Valencia-Orange Leaf Hyperspectral Measurements. **Remote Sens.**, v. 12, n. 906, 2020. DOI:<https://doi.org/10.3390/rs12060906>
- OSCO, L. P. *et al.* A review on deep learning in UAV remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v. 102, p. 102456, 2021. DOI: <https://doi.org/10.1016/j.jag.2021.102456>
- SHALEV-SHWARTZ, S.;BEN-DAVID, S. **Understanding machine learning: From theory to algorithms**. Cambridge: Cambridge University Press, 2013. DOI: <https://doi.org/10.1017/CBO9781107298019>
- SILVA, C. A. M. A. **Previsão do valor Brix: aplicação de algoritmos de Machine Learning**. 2021. Tese (Doutorado) - Instituto Superior de Economia e Gestão, 2021.
- VESSONI, I. C.; MARIANI, A.; ÁVILA, C. J.. **Manejo Integrado de Pragas (MIP) na cultura da soja, Glycine max: viabilidade econômica e benefícios ambientais**. Embrapa Agropecuária Oeste-Outras publicações técnicas (INFOTECA-E), 2020.
- WEST, J. S. *et al.* Detection of fungal diseases optically and pathogen inoculum by air sampling. In: OERKE, E.C., GERHARDS, R., MENZ, G., SIKORA, R.A. (Eds.) **Precision crop protection - the challenge and use of heterogeneity**. Dordrecht: Springer Science+Business Media, 2010. p. 135-149. Disponível em: <https://dokumen.tips/reader/f/precision-crop-protection-the-challenge-and-use-of->

[heterogeneity-](#). Acesso em: 03 mar. 2022. DOI:
https://doi.org/10.1007/978-90-481-9277-9_9