

USO DE INTELIGÊNCIA ARTIFICIAL PARA PREDIÇÃO DE EFICIÊNCIA DE DERRIÇA E PERDA DE CHÃO NA COLHEITA MECÂNICA DO CAFÉ

Luiz de Gonzaga Ferreira Júnior, Eng. Agrícola, Gonzaga Treinamentos e Consultoria Agrícola Ltda (contato@gonzagaconsultoria.com); Túlio Marcos Militani Alves, Eng. Agrícola, DEA/ UFLA; Fernando Elias de Melo Borges, Doutorando DEA/UFLA, Danton Diego Ferreira, Prof. DAT/ UFLA

A constante variação climática e escassez de mão de obra tem tornado a cafeicultura altamente desafiadora. A busca por tecnologias e uso da mecanização para manter a atividade competitiva é fundamental no momento atual da cafeicultura. A variação climática afeta diretamente o ciclo fenológico do cafeeiro, atrasando, adiantando ou interrompendo fases vegetativas e reprodutivas. Com isso, empresas, técnicos e produtores têm buscado tecnologias e inovações que alcancem boas eficiências e minimizem perdas. Baseado nisso, este trabalho propôs o desenvolvimento de modelos que utilizam inteligência artificial para predição da eficiência de derriça e perda de chão causada pela colhedora durante a colheita do café baseado na análise de dados reais de campo por meio do uso de técnicas de aprendizado de máquina (*machine learning*), que é caracterizado pela aquisição de conhecimento por meio da observação e experimentação, ou então pela combinação das duas dimensões. Este método é capaz de desenvolver modelos que se auto incrementam para obtenção de novos conhecimentos e habilidades com identificação de conhecimentos já existentes.

Então, foram desenvolvidos um modelo de rede neural artificial (RNA) capaz de prever a eficiência de derriça e outro capaz de prever a perda de chão, ambos utilizando 34 fatores adquiridos de uma base de dados da empresa LD Gonzaga Treinamentos e Consultoria Agrícola Ltda. Esses dados foram coletados pela equipe da empresa em duas Fazendas no município de Nepomuceno, Sul de Minas Gerais, durante a safra de 2019. Como parte das informações estudadas, destacam-se: regulagens das máquinas colhedoras de café (como velocidade operacional, frequência de vibração dos osciladores e freio da agressão dos osciladores); maturação dos frutos colhidos; data da colheita; espaçamento da lavoura; queda natural de frutos; tipo de máquina e características individuais; operações (primeira ou segunda passada, seletiva e repasse); cultivar e suas características técnicas; área do talhão; informações meteorológicas do local; eficiência de derriça, eficiência de colheita e perda de chão da máquina.

Como primeira análise, utilizou-se o coeficiente de Pearson para avaliar se as variáveis se correlacionam de forma linear com as saídas. Para a criação do modelo de previsão, utilizou-se a ferramenta computacional Synthetic Minority Over-sampling Technique (SMOTE) através do *software* MATLAB, para a criação de 100 amostras de dados sintéticos baseados nas 50 amostras reais já existentes a fim de possibilitar o desenvolvimento do modelo matemático e minimizar erros nas predições.

Para prever a eficiência de derriça e a perda da máquina, utilizou-se a técnica de RNA por meio do *software* *Spyder*, o qual utiliza linguagem de programação Python. Para a verificação da qualidade do modelo desenvolvido pela rede neural foi utilizado o método de validação cruzada do tipo *K-fold*.

Resultados e Conclusões

A velocidade operacional da colhedora apresentou forte correlação inversa com a eficiência, ou seja, quanto maior a velocidade menor a eficiência. Já a vibração mostrou-se correlacionada de forma direta com a eficiência. Os resultados corroboram com os encontrados na literatura e com as práticas aplicadas no dia a dia. Ao observar as correlações entre as regulagens (velocidade e vibração) e a perda de chão ocasionada pela máquina, pode-se notar correlações inferiores se comparadas às correlações com a eficiência. Os freios dos osciladores da colhedora apresentaram forte correlação positiva com a eficiência de derriça e uma correlação um pouco inferior, porém positiva com a perda da máquina.

Observou-se também, correlações lineares entre as características das plantas com a eficiência, destacando-se o porte da planta e o comprimento dos internódios, ambas com correlações positivas. A temperatura média do dia apresentou alta correlação negativa com as eficiências e com a perda da máquina. Além da temperatura, foi possível identificar a participação efetiva de outras variáveis como a umidade relativa média do dia, que apresentou maior valor de correlação linear negativa com a perda da máquina.

Os resultados da validação do modelo de RNA para predição da eficiência de derriça foi realizado com as 50 amostras de dados reais, onde observou-se que a eficiência de derriça foi bem predita utilizando 34 fatores como entrada, obtendo R^2 igual a 0,94 e RMSE (raiz do erro médio quadrático) igual a 0,05. O gráfico da Figura 01A apresenta a eficiência Real e Predita obtida pelo modelo. Para predição da perda de chão ocasionada pela máquina, utilizou-se a mesma quantidade de amostras reais e fatores de entrada e o modelo apresentou R^2 igual 0,93 e um RMSE igual a 0,02, conforme apresentado no gráfico da Figura 01B.

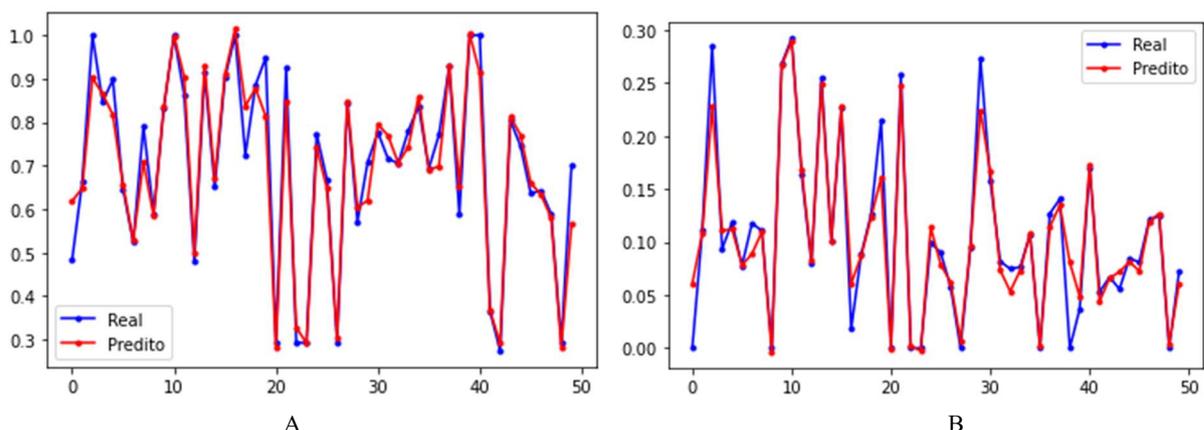


Figura 01: Gráficos da predição da eficiência de derriça e perda de chão, no modelo RNA, onde no eixo x estão as 50 amostras de dados reais (linhas) e no eixo y a eficiência de derriça em taxa unitária em A e perda de chão em taxa unitária em B. Em A, os pontos da linha azul representam a eficiência de derriça real de cada talhão e os pontos da linha vermelha as eficiências preditas pelo modelo

desenvolvido. Em B, os pontos da linha azul representam a perda da máquina real em cada talhão e os pontos da linha vermelha as perdas previstas no modelo de predição desenvolvido.

De forma geral, os modelos mostraram-se altamente eficientes na predição das saídas, sendo elas, eficiência de derriça e perda de chão da máquina. Dentre os 34 fatores estudados, os cinco que mais interferem na eficiência de derriça são: formato de copa, cor do fruto, data da colheita, porte da planta e resposta a poda. Já os cinco fatores que mais interferem na perda da máquina são: escolha da operação (plena ou escalonada), maturação dos frutos, data da colheita, uniformidade de maturação e ajuste do torque no freio dos cilindros osciladores da colhedora.

Com a aplicação dos dois modelos de RNA, conclui-se que os 34 fatores descrevem bem a operação de colheita mecanizada do café, e que os modelos de predição desenvolvidos se mostraram eficientes, uma vez que várias recomendações baseadas no modelo RNA condizem com recomendações de boas práticas realizadas por consultores e técnicos da área de mecanização da colheita do café. Além da predição, o uso do aprendizado de máquina apontou também relevância em fatores antes não imagináveis nem apontados ou comprovados com embasamento científico em pesquisas sobre colheita mecanizada do café, como é o caso dos fatores “cor do fruto”, “resposta a poda”, “comprimento dos internódios”, “queda natural” e os fatores relacionados ao clima, como “velocidade do vento”, “temperatura” e “umidade relativa do ar”.