

COMPARAÇÃO DE ARQUITETURAS DE REDES NEURAIS ARTIFICIAIS PARA CLASSIFICAÇÃO DE STATUS DE NITROGÊNIO EM *BRACHIARIA DECUMBENS* CV. BASILISK

30° Zootec, 1ª edição, de 10/05/2021 a 14/05/2021

ISBN dos Anais: 978-65-89908-12-8

BERTOLINI; Caio Augusto¹, MATUO; Caroline Megumi², SILVA; Ilara Rodrigues³, TECH; Adriano Rogério Bruno⁴, PEREIRA; Lilian Elgalise Techio⁵

RESUMO

Redes neurais artificiais (RNA's) são modelos computacionais de aprendizado de máquina capazes de classificar e interpretar informações complexas. Os componentes das RNA's são chamados neurônios. Neurônios da camada de entrada recebem sinais do meio externo (dados) e, através das 'conexões sinápticas' que os interligam realizam um processamento, ponderando a influência de cada sinal de entrada (pesos). Essa ponderação é realizada nas camadas intermediárias onde se realiza o treinamento da rede. O aprendizado ocorre quando uma solução generalizada para um problema é obtida, sendo o resultado apresentado pela camada de saída. Uma RNA é especificada pela sua arquitetura (topologia), caracterizada pelo número de camadas intermediárias e neurônios em cada camada, regras de treinamento e funções de ativação. Um dos tipos de RNA's mais comuns são as *Multilayer Perceptron* (MLP), que permitem definir o número de camadas intermediárias e o número de neurônios contidos nestas. O treinamento da MLP obedece ao aprendizado supervisionado, onde cada dado de entrada possui uma classificação associada, para que a rede aprenda a identificar os padrões conhecidos. A topologia ideal de uma RNA deve ser capaz de obter as representações necessárias com o melhor desempenho possível, em processos de treinamento rápidos e com baixo custo computacional. Todavia, não existem regras claras para definição das arquiteturas mais adequadas. Assim, o objetivo deste trabalho foi encontrar a melhor arquitetura da rede MLP para classificação do status de nitrogênio (N) em pastagens de *Brachiaria decumbens* 'Basilisk' a partir de imagens. O experimento para aquisição de imagens foi realizado na FZEA/USP, Pirassununga-SP, entre dezembro/2019 e abril/2020. O banco de dados continha 1080 imagens de folhas individuais, de onde foram extraídos 29 índices de vegetação (neurônios na camada de entrada) baseados no modelo RGB. Cada imagem possuía uma classificação, segundo o status de N (método Kjeldhal): deficiente, moderadamente deficiente e suficiente. As topologias continham uma camada intermediária e utilizaram o algoritmo de treinamento com retropropagação do erro. Foram testadas 24 arquiteturas com 5 ou 10 neurônios, funções de treinamento quasi-Newton (L-BFGS), gradiente descendente estocástico (SGD) e o método otimizador estocástico baseado em gradiente (ADAM), e funções de ativação *Identity*, *Logistic*, *Tansig* e *Relu*. O *F1-score* foi utilizado para avaliação do desempenho. Independentemente do número de neurônios da camada intermediária e função de treinamento, as funções de ativação *Identity* e *Tansig* apresentaram melhor desempenho, com *F1-score* entre 62% a 76%, enquanto *Logistic* demonstrou baixo desempenho na classificação das imagens. Entre as funções de treinamento, a L-BFGS resultou em melhor desempenho geral (*F1-score* >75%). Em todas as topologias testadas não foram observadas melhorias significativas no desempenho com o aumento do número de neurônios de 5 para 10. Topologias com menor desempenho geral foram SGD (29-5-1)/(29-10-1) com função de ativação *Logistic* (*F1-score* abaixo de 50%). Assim, para classificação do status de N da *B. decumbens* a partir de imagens de folhas, recomendam-se topologias que utilizam função de treinamento L-BFGS com 5 neurônios na camada intermediária e função de ativação *Identity* (76,1%) ou L-BFGS com 10 neurônios e

¹ Pós-graduando - FZEA-USP, caio.augusto.bertolini@usp.br

² Graduanda em zootecnia - FZEA-USP, caroline.matu@usp.br

³ Graduanda em zootecnia - FZEA-USP, ilara.silva@usp.br

⁴ Professor Doutor - FZEA-USP, adriano.tech@usp.br

⁵ Professora Doutora - FZEA-USP, ltechio@usp.br

funções de ativação *Tansig* (76,1%) ou *Relu* (76,3%).

PALAVRAS-CHAVE: Forragicultura e pastagens, Aprendizado de máquina, Processamento de imagens, RNA, Teor de nitrogênio

¹ Pós-graduando - FZEA-USP, caio.augusto.bertolini@usp.br
² Graduanda em zootecnia - FZEA-USP, caroline.matuo@usp.br
³ Graduanda em zootecnia - FZEA-USP, ilnara.silva@usp.br
⁴ Professor Doutor - FZEA-USP, adriano.tech@usp.br
⁵ Professora Doutora - FZEA-USP, ltechio@usp.br