

ÁRVORES DE DECISÃO COMO SOLUÇÃO PARA AJUSTE DE MODELO DE PREDIÇÃO PARA AGRICULTURA DIGITAL

LEMONS, D. L.¹, DURGANTE, B. O.¹, PEREZ, N. B.², PINHO, L. B.¹.

¹ Universidade Federal do Pampa – Bagé – RS – Brasil – {davilemos.aluno,
biancadurgante.aluno, leonardopinho}@unipampa.edu.br

² Embrapa Pecuária Sul – Bagé – RS – Brasil – naylor.perez@embrapa.br

RESUMO

Este trabalho investiga o uso de Árvores de Decisão (AD) como alternativa mais eficiente para o ajuste fino de hiperparâmetros em modelos de predição aplicados à agricultura digital. Métodos automáticos como o KerasTuner (KT), embora comuns, podem ter limitações em acurácia e custo computacional. Propõe-se o uso de AD para otimizar o processo, reduzindo o tempo de treinamento e aumentando a precisão das previsões. Experimentos com RRN de arquitetura LSTM indicam que esta técnica supera esses métodos tradicionais, prevendo 90% dos ajustes inadequados e 67% dos ajustes adequados, e ainda apresentando redução de 55% do tempo de execução com acurácia semelhante quando comparado ao KT.

Palavras-chave: Inteligência Artificial, Pecuária de Precisão, Computação Verde.

1 INTRODUÇÃO

O uso de tecnologias voltadas ao apoio à gestão agrícola está em ascendência e comumente nota-se o uso de aplicações relativas ao aprendizado profundo, que consiste em uma classe de técnicas de aprendizado de máquina. A utilização de artifícios como este possibilita, por exemplo, um manejo preciso e inteligente dos animais na pastagem, auxiliando no gerenciamento da disponibilidade de alimento de forma adequada e alavancando o ganho de peso do rebanho fazendo com que haja mais retorno financeiro ao produtor.

Tendo em vista isso, Schulte (2019) propôs uma aplicação capaz de prever, através de amostras climáticas e de ambiente, a massa de forragem esperada para os meses subsequentes. Entretanto, a aplicação possui elevado tempo de treinamento levando em conta o número de instâncias utilizadas e a configuração das variáveis que impactam diretamente no desempenho da rede: os hiperparâmetros. Isso acaba elevando seu custo computacional, já que esta depende de re-treinamento perante o constante abastecimento de novos dados para

maior acurácia das predições, indo em contrapartida aos aspectos ambientais, sociais e de governança (ESG), bem como da computação verde.

A técnica de sintonização de redes neurais via ajuste empírico, aplicada no modelo citado, vem entrando em desuso perante o surgimento de ferramentas de autoajuste, as quais têm a premissa de realizar um ajuste fino desses hiperparâmetros, proporcionando uma maior acurácia e, assim, banalizando a escolha manual. Entretanto, conforme elucidado por Lemos *et al.* (2024), há impacto considerável no desempenho do algoritmo com a adição desta técnica de sintonização via KerasTuner (KT) (O'Malley *et al.*, 2019), que por sua vez não garante adaptabilidade a todos modelos em que pode ser aplicada, como é o caso de Soares (2021), uma versão aprimorada do algoritmo de Schulte (2019), em que o sintonizador não superou a acurácia do ajuste empírico em nenhum caso.

Dessa forma, garantir que não sejam realizados treinamentos em vão, quando aplica-se um ajuste empírico irregular, alcançando resultados insatisfatórios, mas ainda assim mitigando o tempo de sintonização agregado pelo uso de ferramentas de autoajuste, é de suma importância. Busca-se encontrar uma nova técnica que avalie os ajustes empíricos através de um conjunto de dados contendo hiperparâmetros e suas respectivas acurácias mensuradas pelo Erro Médio Quadrático (RMSE), medido em quilogramas por hectare (kg/ha). A construção deste novo método se dá através do algoritmo para aprendizado de máquina de Árvores de Decisão (AD), que consiste em uma estrutura de dados definida recursivamente (Monard *et al.*, 2003), de forma que evite treinamentos ociosos e amplie o desempenho da aplicação, demonstrando a relevância desta pesquisa.

2 METODOLOGIA (MATERIAL E MÉTODOS)

Esta pesquisa exploratória experimental se propõe a mapear a acurácia da ferramenta proposta por Schulte (2019) levando em consideração os hiperparâmetros do modelo. O funcionamento consiste no uso de Redes Neurais Recorrentes (RNN) de arquitetura *Long Short-Term Memory* (LSTM), assim tendo em consideração a sequencialidade temporal das amostras, que, por sua vez, tem suas datas de coleta entre os anos de 2014 e 2019 e são oriundas de experimentos com pecuária de campo nativo características do bioma Pampa, sendo processadas por duas camadas de neurônios.

Com o objetivo de levantar o conjunto de dados aplicados nos testes, o qual será responsável por conter a relação entre a escolha de hiperparâmetros e a

acurácia do modelo, utiliza-se a ferramenta KT, um autoajustador destas variáveis que testa, no método RandomSearch (busca aleatória), diferentes combinações delas e avalia com base no erro o melhor conjunto encontrado, desempenhando papel crucial para otimização na obtenção de dados visto que a escolha empírica destas combinações levaria considerável tempo. Desta forma, para proporcionar maior consistência aos dados coletados e reduzir impactos causados pela randomicidade do algoritmo aplicado são analisadas 100 amostras.

Este estudo analisa quatro hiperparâmetros configurados para a Rede Neural Recorrente (RNN): quantidade de neurônios, estado do *dropout*, função de ativação e taxa de aprendizado. A quantidade de neurônios refere-se ao número de unidades ocultas em uma camada, crucial para capturar padrões complexos nos dados. A taxa de aprendizado controla a velocidade de ajuste dos parâmetros do modelo durante o treinamento, enquanto o *dropout*, técnica que desliga uma porcentagem de neurônios, promove a aprendizagem de representações independentes. As funções de ativação introduzem não-linearidade ao modelo, permitindo modelagem de relações complexas, com ênfase nas funções Tanh e ReLU (Reis, 2018).

Para avaliar a acurácia da aplicação, utiliza-se a estrutura de dados AD, implementada na biblioteca "scikit-learn" da linguagem Python. O algoritmo processa um arquivo CSV contendo amostras com seis atributos: quantidade de neurônios da primeira e segunda camadas, estado do dropout, função de ativação, taxa de aprendizado e qualidade do ajuste, classificada como adequada se o RMSE for menor que 1700 kg/ha. Os atributos categóricos são normalizados, onde zero representa falso e um representa verdadeiro no caso do *dropout*, e zero e um são atribuídos a ReLU e Tanh, respectivamente, na função de ativação.

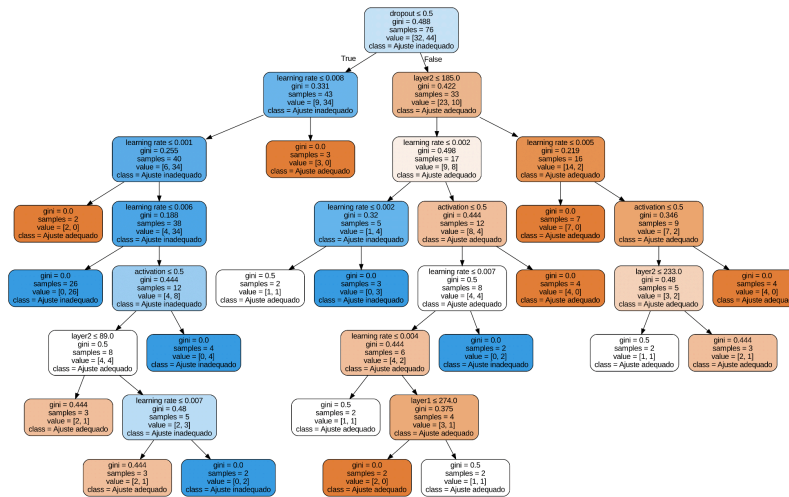
Na execução de algoritmos de aprendizagem profunda e de mineração de dados, como os do presente caso, demanda-se o uso de recursos computacionais para que o seu desempenho seja ampliado, portanto, na realização dos testes desta pesquisa emprega-se um computador do tipo notebook, com microprocessador *multicore* AMD Ryzen 7 5700U com frequência de até 4,3 GHz e 8 núcleos com 16 threads, placa de vídeo integrada AMD Radeon Graphics 8, 12 GB de memória DDR4 e sistema operacional Ubuntu 24.04 LTS.

3 RESULTADOS E DISCUSSÃO

Através da fundamentação teórica e métodos apresentados nas seções anteriores, com os dados constatados nos experimentos foi possível o

desenvolvimento de uma AD. Esta é capaz de prever, com uma acurácia de 90%, ajustes inadequados (que ultrapassam o valor máximo), e com uma acurácia de 67% para a predição de ajustes adequados. A Figura 1 apresenta a solução proposta graficamente.

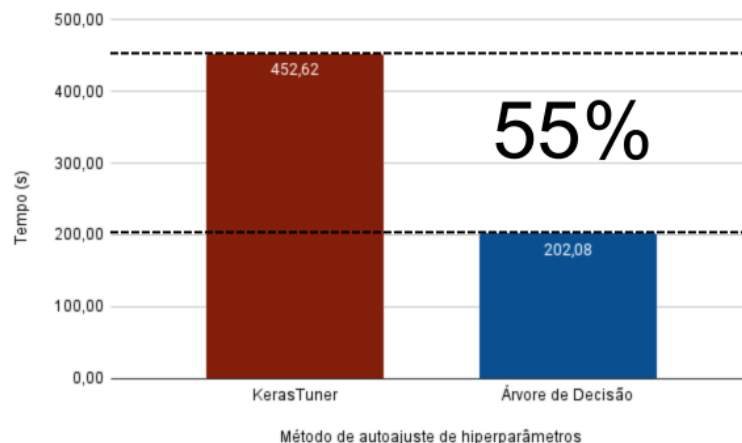
Figura 1. Árvore de Decisão implementada



Fonte: próprio autor.

Para verificar a aplicabilidade do método proposto, compara-se o autoajuste via KT e AD com combinações aleatórias de hiperparâmetros. Conforme a Figura 2, observa-se que AD apresenta desempenho superior, reduzindo o tempo de execução total da aplicação em 55%. Posto que a fonte de dados meteorológicos do modelo é atualizada quatro vezes ao dia, estima-se que para manter-se atualizada a aplicação precisaria ser re-treinada aproximadamente 960 vezes ao ano. Nesse contexto, a adoção de AD permitiria reduzir o tempo de execução em cerca de 67 horas por ano, sem perda de acurácia.

Figura 2. Tempo de execução x Método de autoajuste



Fonte: próprio autor.

4 CONCLUSÃO

A pesquisa evidencia a eficácia das AD como uma alternativa eficiente para o ajuste fino de hiperparâmetros em modelos de predição na agricultura digital. Os resultados indicam que essa abordagem supera as limitações de autoajustadores como o KT, posto que, além de manter a acurácia, a adoção de AD proporciona uma redução de 55% no tempo de execução. Além disso, destaca-se a importância da escolha correta dos métodos em um contexto de crescente demanda por soluções eficientes, como as AD deste trabalho, que fomentam o uso responsável de recursos tecnológicos e promovem computação sustentável. Conclui-se que a metodologia proposta pode ser amplamente aplicada em cenários de aprendizado de máquina, não apenas na agricultura, mas também em outras áreas que exigem precisão em modelos preditivos. Reconhece-se o apoio da CAPES - Código de Financiamento 001 e dos Programas Institucionais de Bolsas de Iniciação Científica PROBIC/FAPERGS, PIBIC/CNPq e PRO-IC/UNIPAMPA.

REFERÊNCIAS

- LEMOS, Davi L.; DURGANTE, Bianca O.; PEREZ, Naylor B.; PINHO, Leonardo B. **Impactos da Ferramenta KerasTuner em Modelo de Predição Baseado em LSTM para Pecuária Sustentável**. In: ERAD-RS, 2024, Florianópolis. Anais [...]. POA: SBC, 2024. p. 97-100.
- MONARD, M. C.; BARANAUSKAS, José Augusto. **Indução de Regras e Árvores de Decisão**. In: REZENDE, Solange O. (Org.). **Sistemas Inteligentes: Fundamentos e Aplicações**. 1. ed. Barueri-SP: Manole, 2003. p. 115-140.
- O'MALLEY, Tom; BURSZTEIN, Elie; LONG, James; CHOLLET, François; JIN, Haifeng; INVERNIZZI, Luca; *et al.* **KerasTuner**. 2019. Disponível em: <https://github.com/keras-team/keras-tuner>. Acesso em: 25 ago. 2024.
- SCHULTE, Leonardo Gauer. **Suporte à decisão em pastagens: análise espaço-temporal e aprendizado de máquina para predição da disponibilidade de forragem**. 2019. Dissertação (Mestrado) – UNIPAMPA, Bagé.
- SOARES, Ânderson Fiscoeder. **TouceiraTech: um Farm Management Information System para pecuária de precisão baseado em predição com redes neurais recorrentes**. 2021. Dissertação (Mestrado) – UNIPAMPA, Bagé.
- REIS, Carlos Henrique. **Otimização de Hiperparâmetros em Redes Neurais Profundas**. 2018. Monografia (Graduação) – Universidade Federal de Itajubá, Itajubá.