

VARIÁVEIS EXPLICATIVAS NA ESTIMATIVA DA TEMPERATURA MÍNIMA DO AR

Frank Freire Capuchinho¹, Francisco Ramos de Melo², Kedinna Dias de Sousa¹, Gabriella Andrezza Meireles Campos², Jefferson Souza e Silva²
frankfreirec@gmail.com, Francisco.melo@ueg.br, kedinnads@hotmail.com, g_abicampos@hotmail.com, jeffersonarar@gmail.com

¹ Universidade Federal de Goiás - UFG, Pós-Graduação em Agronomia¹, Goiânia, Goiás

² Universidade Estadual de Goiás - UEG, Pós-Graduação em Engenharia Agrícola², Anápolis, Goiás

RESUMO: Existem diversos fatores geográficos e climáticos que afetam variabilidade da temperatura mínima do ar (T_{min}), sendo importante identificar aqueles que possibilitam melhor precisão das estimativas. O objetivo deste trabalho foi o de utilizar o Deep Learning para selecionar as variáveis explicativas que proporcionam melhores estimativas da T_{min} mensal, para a região Centro-Oeste do Brasil. Foram utilizados dados de estações meteorológicas localizadas na região Centro-Oeste do Brasil. As variáveis utilizadas para as estimativas da T_{min} , foram: altitude (Alt), latitude (Lat), longitude (Long), umidade relativa do ar (UR) e velocidade do vento (VV). Foram estudadas cinco combinações de cenários (C1 a C5) dos parâmetros explicativos. As Redes Neurais Artificiais (RNAs) foram desenvolvidas, para cada mês do ano e para cada cenário, totalizando 60 RNAs. Para avaliar a precisão das estimativas foi utilizado o coeficiente de correlação de Pearson (r). Somente no C5 para os meses de maio (28%) e setembro (38%) é que foram obtidos (r) classificados como fracos ($r < 0,4$). Exceto nestas circunstâncias (C5 em maio e setembro), as diferentes combinações de variáveis de entrada e a aplicação de Deep Learning foram capazes de estimar a T_{min} mensal, para a região Centro-Oeste do Brasil com precisão satisfatória.

Palavras-Chave: Agrometeorologia. Biga Data. Deep Learning. Inteligência Artificial.

EXPLANATORY VARIABLES IN THE ESTIMATED MINIMUM AIR TEMPERATURE

ABSTRACT: There are several geographic and climatic factors that affect the variability of the minimum air temperature (T_{min}), and it is important to identify those that allow better precision of the estimates. The objective of this work was to use Deep Learning to select the explanatory variables that provide better estimates of the monthly T_{min} for the Midwest region of Brazil. Data

from meteorological stations located in the Midwest region of Brazil were used. The variables used to estimate the T_{min} were altitude (Alt), latitude (Lat), longitude (Long), relative humidity (RH) and wind speed (WS). Five combinations of scenarios (S1 to S5) of the explanatory parameters were studied. Artificial Neural Networks (ANNs) were developed for each month of the year and for each scenario, totaling 60 ANNs. To assess the accuracy of the estimates, Pearson's correlation coefficient (r) was used. Only in S5 for the months of May (28%) and September (38%) were obtained (r) classified as weak ($r < 0.4$). Except under these circumstances (S5 in May and September), the different combinations of input variables and the application of Deep Learning were able to estimate the monthly T_{min} for the Midwest region of Brazil with satisfactory accuracy.

Keywords: Agrometeorology. Artificial Intelligence. Big Data. Deep Learning.

1. INTRODUÇÃO

O desenvolvimento fisiológico de animais e vegetais está relacionado diretamente com temperatura do ar. Isso porque algumas espécies são mais suscetíveis que outras, especificamente, aos níveis mínimos de temperatura do ar. Nesse contexto, determinar a temperatura mínima do ar é importante pois possibilita que os produtores rurais e os órgãos governamentais possam planejar as atividades agropecuárias de maneira otimizada (REIS et al., 2017).

Existem diversos fatores geográficos e climáticos que afetam a T_{min} , como por exemplo a altitude, latitude, longitude, umidade relativa do ar e velocidade do vento. Dessa maneira, torna-se importante identificar os fatores e elementos de forma a possibilitar uma melhor precisão nas estimativas da T_{min} .

Dentre os métodos que podem ser aplicados para identificar a relevância das variáveis explicativas na estimativa da T_{min} , tem-se as Redes Neurais Artificiais (RNA's) Deep Learning. As RNAs são sistemas computacionais constituídos por unidades de processamento simples (neurônios artificiais), conectadas entre si de maneira específica para desempenhar determinada tarefa (BINOTI et al., 2013; HAYKIN, 1999).

Já a abordagem Deep Learning apresenta diversas camadas intermediárias e 'N' neurônios,

com alterações lineares e não lineares. Usualmente a abordagem Deep Learning tem sido aplicada para a resolução de problemas que envolvam um grande volume de dados (*Big Data*), como é o caso do estudo de séries temporais climáticas (FERLIN e REZENDE, 2019). Portanto, o objetivo deste trabalho foi o de utilizar o Deep Learning para selecionar as variáveis independentes que proporcionam melhores estimativas da T_{min} mensal, para a região Centro-Oeste do Brasil.

2. FUNDAMENTAÇÃO TEÓRICA

O clima de uma região ou local é altamente influenciado por elementos e fatores meteorológicos que variam no tempo e no espaço. Dentre eles podem ser citados a latitude, a longitude, a altitude, a umidade relativa do ar, velocidade de ventos, nebulosidade, radiação solar, a presença de corpos hídricos, a presença e o tipo de vegetação local, maciços montanhosos, usos de terra, correntes marítimas, compostos atmosféricos, dentre outros (SILVA et al., 2019; AQUINO et al., 2016).

Neste contexto, a temperatura mínima do ar está diretamente relacionada nas atividades desenvolvidas pela sociedade, a exemplo da produção de alimentos. Especificamente quanto a sua influência no meio rural, a temperatura mínima do ar é capaz de atuar sobre a fisiologia de vegetais e animais. Portanto, a determinação desse elemento meteorológico possibilita aos produtores e órgãos governamentais o planejamento das atividades agropecuárias de forma otimizada (SOUZA e MARTINS, 2014; KERBAUY, 2008; WALTZ et al., 2014; GUIMARÃES et al., 2014; REIS et al., 2014).

Entretanto, no que se diz respeito ao conhecimento das variáveis explicativas, no mundo real nem sempre é possível estudar todos os fatores e elementos que explicam as oscilações das variáveis respostas, como é o caso da temperatura mínima do ar. Isso porque podem ocorrer falhas e indisponibilidade de dados meteorológicos, além da própria dificuldade em se mensurar espacialmente e historicamente outras variáveis. Neste sentido, se faz necessário o estudo de combinações das variáveis explicativas disponíveis que possam proporcionar estimativas adequadas (PRASAD et al., 2017; MEENAL et al., 2018).

Para contornar tais problemas, o emprego de metodologias específicas, em especial as Redes Neurais Artificiais Deep Learning, pode ser uma alternativa para solucionar problemas complexos – de elevada quantidade de dados e relação entre fatores explicativos – na identificação das combinações ideais de variáveis explicativas.

As RNAs são modelos matemáticos capazes de aprender por meio de exemplos e extrair informações mesmo que essas relações físicas dos processos não estejam explícitas (ULIANA *et al.*, 2018). Especificamente tem-se as RNAs Multicamadas que contam com a camada de entrada, uma ou mais camadas intermediárias e camada de saída. Já a abordagem Deep Learning apresenta diversas camadas intermediárias e ‘N’ neurônios, com alterações lineares e não lineares. Usualmente a abordagem Deep Learning tem sido aplicada para a resolução de problemas que envolvam um grande volume de dados (*Big Data*), como é o caso do estudo de séries temporais climáticas (FERLIN e REZENDE, 2019).

3. MATERIAL E MÉTODOS

O trabalho foi desenvolvido no Laboratório de Engenharia Agrícola da Universidade Estadual de Goiás, Campus Central – CET, sede Anápolis/GO. A região estudada foi o Centro-Oeste do Brasil, nos estados de Goiás, Mato Grosso, Mato Grosso do Sul e Distrito Federal de 81 estações meteorológicas localizadas nestes estados.

Foram utilizados dados geográficos (altitude, latitude e longitude) e dados climáticos diários da temperatura mínima do ar (Tmin), velocidade do vento (VV) e umidade relativa do ar (UR) de estações automáticas. Os dados foram obtidos na plataforma online do Instituto Nacional de Meteorologia (2020), referentes ao período com disponibilidade de dados entre 2000 e 2020.

Para preencher as falhas de dados observados nas estações meteorológicas automáticas e completar a série estipulada 30 anos (1990-2020), foi utilizado banco de dados desenvolvido por Xavier *et al.* (2015) para o Brasil no *software* R versão 3.6.1. Em cada município, foram determinadas as médias mensais da Tmin (°C), UR (%), e VV (m.s⁻¹), de modo a completar os 12 meses do ano, por um período de 30 anos. Foi utilizada uma amostragem de 60% para a etapa de treinamento da rede e 20% para a etapa de validação e 20% para o teste (COUTINHO *et al.*, 2018).

Foram desenvolvidas Redes Neurais Artificiais Deep Learning (RNAs) no software R, com


configuração de três camadas intermediárias (17-7-3) e função de transferência *rectified linear unit* (ReLU). Para as variáveis de entrada foram analisados 05 diferentes cenários (C1 a C5), sendo eles: C1 (Alt, Lat, Long, UR e VV); C2 (Alt, Lat, Long e UR); C3 (Alt, Lat e Long); C4 (Alt, Lat, Long e VV) e C5 (Alt, Lat e VV). Dessa maneira, foram geradas RNAs para cada mês do ano e para cada cenário analisado, totalizando 60 RNAs.

Para a validação das redes em relação aos valores observados os estimados em cada cenário, foi utilizado o coeficiente de correlação de Pearson 'r', para as parcelas (20%) dos dados que não foram utilizadas na etapa de treino e validação e em todos os meses do ano, para a temperatura mínima do ar mínima, na escala mensal.

4. RESULTADOS E DISCUSSÃO

Na Figura 1 são apresentados os resultados de Coeficiente de Correlação de Pearson 'r' entre valores observados e simulados pelas Redes Neurais Artificiais (RNAs) nas estimativas das temperaturas do ar mínima (Tmin) em diferentes cenários (C1-C5) para o Centro-Oeste do Brasil.

Figura 1 - Coeficiente de Correlação de Pearson (r, em %) entre valores observados e simulados pelas Redes Neurais Artificiais (RNAs) na estimativa da temperatura do ar mínima (Tmin) mensal, em diferentes cenários (C1-C5) para o Centro-Oeste do Brasil.



Fonte: Elaborado pelo Autor.

Os coeficientes de correlação de Pearson variaram de 94,1% (C3 no mês de abril) a 28,5%

(C5 no mês de maio). Somente no C5 para os meses de maio (28%) e setembro (38%) é que foram obtidos coeficientes de correlação classificados como uma correlação fraca positiva (0,1 – 0,39) (DANCEY e REIDY, 2005).

A correlação classificada como moderada positiva (0,4 – 0,69) (DANCEY e REIDY, 2005), foi observado no cenário C2 em janeiro (59%), julho (63%) e agosto (64%); cenários C3 e C4 obtiveram 54 e 64%, respectivamente, ambos no mês de agosto e, no C5 junho (46%), julho (56%), e outubro (65%). Os restantes dos meses e cenários, obtiveram resultados satisfatórios de coeficiente de correlação ($r \geq 0,7$) entre valores estimados e simulados pelas RNAs, indicando que essa abordagem é capaz de estimar a T_{min} mensal, com precisão satisfatória, para a região Centro-Oeste do Brasil.

Trabalhos desenvolvidos a exemplo de Prasad et al. (2017), verificaram 23 variáveis de entrada, no qual o menor e o maior valor de r (0,29 e 0,96) foi na combinação de 03 e 10 variáveis de entrada, respectivamente. Já Meenal et al. (2018) analisaram redes neurais artificiais com 07 e 05 variáveis de entrada. O menor valor ($r = 0,77$) foi obtido na rede com 05 variáveis independentes enquanto o maior valor ($r = 0,98$) foi obtido na rede com 07 neurônios na camada de entrada.

Para as RNAs que obtiveram ‘ r ’ classificados como moderados e altos, a abordagem Deep Learning foi capaz de estimar a T_{min}, com correlações satisfatórias em todos os cenários estudados (5, 4 e 3 neurônios na camada de entrada). Especificamente para os resultados obtidos no cenário C1 (Alt, Lat, Long, UR e VV), os valores de (r) foram superiores a 75% ($r > 75\%$), indicando que todas as variáveis foram capazes de explicar a variabilidade da T_{min} em todos os meses do ano.

5. CONCLUSÃO

As diferentes combinações estudadas nos cenários C1, C2, C3 e C4 apresentaram correlações positivas fortes e moderadas, sendo estes resultados considerados satisfatórios para o estudo. Os resultados obtidos para o cenário C1 (Alt, Lat, Long, UR e VV) destaca-se com valores de $r > 75\%$, indicando que todas as variáveis foram capazes de explicar a variabilidade da T_{min} em todos os meses do ano.

A quantidade de neurônios na camada de entrada indica que 5, 4 e 3 neurônios foram capazes de estimar a T_{min} . Entretanto, a combinação ideal entre variáveis explicativas considerando a variabilidade temporal, foram fatores que causaram oscilações do coeficiente de correlação.

De forma geral, exceto no cenário C5 (Alt, Long e VV) nos meses de maio e setembro, as diferentes combinações de variáveis de entrada, a quantidade de neurônios na camada de entrada e a aplicação de Deep Learning foram capazes de estimar a T_{min} mensal, para a região Centro-Oeste do Brasil com precisão satisfatória.

AGRADECIMENTOS

Os autores agradecem ao Instituto Nacional de Meteorologia (INMET) pela disponibilidade dos dados. À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) pela bolsa concedida ao autor. Ao Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola (PPGEA) da Universidade Estadual de Goiás e ao Programa de Pós-Graduação *Stricto Sensu* em Agronomia (PPGA) da Universidade Federal de Goiás.

REFERÊNCIAS

AQUINO, P.S.R.; RODRIGUES, M.S.; CASTRO, R.V.O.; NAPPO, M.E. Uso de redes neurais artificiais na análise de variáveis ambientais associadas à deposição de serapilheira. **Revista Comunicata Scientiae**, Bom Jesus, v.7, n.3, p.394-405, 2016.

BINOTI, M.L.M. DA S.; BINOTI, D.H.B.; LEITE, H.G. Aplicação de Redes Neurais Artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, Viçosa, v.37, n.4, p.639–645, 2013.

COUTINHO, E.R.; SILVA, R.M.; MADEIRA, J.G.F.; COUTINHO, P.R.O.S.; BOLOY, R.A.M.; DELGADO, A.R.S. Application of artificial neural networks (ANNs) in the gap filling of meteorological time series. **Revista Brasileira de Meteorologia**, São José dos Campos, v.33, n.2, p.317-328, 2018.

DANCEY, C.P.; REIDY, J. **Estatística sem matemática**: para psicologia usando SPSS para Windows. 3.ed. Porto Alegre: Artmed, 2006. 608p.

FERLIN, E.P.; REZENDE, D.A. *Big Data* aplicado à cidade digital estratégica: estudo sobre o volume de dados das aplicações *smart city*. **Revista Gestão & Tecnologia**, Pedro Leopoldo, v. 19, n. 2, p. 175-194, 2019.

GUIMARÃES, M.C.C.; FURTADO, D.A.; NASCIMENTO, J.W.B.; TOTA, L.C.A.; SILVA, C.M.; LOPES, K.B. Efeito da estação do ano sobre o desempenho produtivo de codornas no semiárido paraibano. **Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.2, p.231–237, 2014.

HAYKIN, S. **Neural Networks and Learning Machines**. 3.ed. New Jersey: Pearson Education, 1999. 906p.

INSTITUTO NACIONAL DE METEOROLOGIA. **Banco de dados meteorológicos para ensino e pesquisa - INMET**, 2020. Disponível em: < <https://www.inmet.gov.br/> >. Acesso em: 20 de nov. de 2020.

KERBAUY, G. B. **Fisiologia Vegetal**. 2 ed. São Paulo: Guanabara Koogan, 2008. 452p.

MEENAL, R.; SELVAKUMAR, A.I. Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters. **Renewable Energy**, Amsterdã, v.121, p.324-343, 2018.

PRASAD, R.; DEO, R. C.; LI, Y.; MARASENI, T. Input selection and performance optimization of ANN-based streamflow forecasts in the drought-prone Murray Darling Basin region using IIS AND MODWT algorithm. **Atmospheric Research**, Amsterdã, v.197, p.42-63, 2017.

REIS, C.J.; BEIJO, L.A.; AVELAR, F.G. Temperatura mínima esperada para Piracicaba-SP via distribuições de valores extremos. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.11, n.4, p.1639-1650, 2017.

SILVA, D.A.P.; CAMPOS, M.C.C.; MONTOVANELLI, B.C.; SANTOS, A.C.; SOARES, M.D.R.; CUNHA, J.M. Variabilidade espacial da emissão de CO₂, temperatura e umidade do solo em área de pastagem na região Amazônica, Brasil. **Revista Ciências Agroveterinárias**, Lages, v.18, n.1, p.119-126, 2019.

SOUZA, P.M.B.; MARTINS, F.B. Estimativa da temperatura basal inferior para as cultivares de oliveira Grappolo e Maria da Fé. **Revista Brasileira de Meteorologia**, São José dos Campos, v.29, n.2, p.307–313, 2014.

ULIANA, E.M.; SILVA, D.D.; MOREIRA, M.C.; PEREIRA, D.R.; PEREIRA, S.B.; ALMEIDA, F.T. Desenvolvimento de Redes Neurais Artificiais para estimativa das vazões diárias na bacia do Rio Piracicaba. **Irriga**, Botucatu, v.23, n.4, p.756–772, 2018.

WALTZ, X.; BAILLOT, M.; CONNES, P.; BOCAGE, B.; RENAUDEAU, D. Effects of hydration level and heat stress on thermoregulatory responses, hematological and blood rheological properties in growing pigs. **PLOS ONE**, San Francisco, v.9, n.7, p.1-7, 2014.

XAVIER, A.C.; KING, C.W.; SCANLON, B.R. Daily gridded meteorological variables in Brazil (1980-2013). **International Journal of Climatology**, Reading, v.36, p.2644-2659, 2015.