













Modelos fuzzy e neuro-fuzzy para predição de variáveis fisiológicas em ovinos com base em dados micrometeorológicos

Raquel Rafael de Freitas SILVA ¹, Sílvia Helena Nogueira TURCO ¹, Dian LOURENÇONI ¹,
Pablo Teixeira Leal de OLIVEIRA ², Hugo Colombaroli BONFÁ ¹, Otoniel Cajú BONFIM ¹,
Luana Barbosa Freire de FIGUEIREDO ¹, Marcio Luiz Santana de ARGOLO FILHO ³,
Luana Carolina Rocha QUEIROZ ¹, Magno do Nascimento AMORIM ⁴

¹ Universidade Federal do Vale do São Francisco, Juazeiro, Bahia, Brasil.

² Instituto Federal do Sertão Pernambucano, Petrolina, PE, Brasil.

³ Universidade do Estado da Bahia, Juazeiro, Bahia, Brasil.

⁴ Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, São Paulo, Brasil.

*E-mail: magnoamorim@usp.br

Submetido em: 16/01/2025; Aceito em: 12/08/2025; Publicado em: 26/08/2025.

RESUMO: O uso de modelos computacionais e termografia viabiliza sistemas automáticos para monitorar o conforto térmico em animais de produção. Este estudo desenvolveu modelos fuzzy e neuro-fuzzy para prever variáveis fisiológicas em ovinos com base em variáveis micrometeorológicas. Os dados micrometeorológicos foram obtidos por um termômetro de globo negro, enquanto os dados fisiológicos incluíram temperatura retal e temperaturas superficiais ocular, do flanco e da costela. Foram coletados 396 pontos de dados, de 18 ovinos, em dois períodos diários. Os modelos foram criados no MATLAB, utilizando temperatura e umidade do ar como variáveis de entrada e os dados fisiológicos como saídas. A avaliação do desempenho considerou estatísticas como erro médio absoluto (MAE), erro percentual absoluto médio (MAPE), erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE) e índice de eficiência (NSE). O modelo neuro-fuzzy teve melhor desempenho comparado ao fuzzy, mas ambos apresentaram bons resultados. Esses modelos eliminam coletas invasivas, economizam tempo e recursos humanos e possibilitam a automação com maior precisão na análise de estresse térmico e bem-estar animal. A abordagem demonstrou-se eficiente para estimar variáveis fisiológicas, contribuindo para avanços no monitoramento do conforto térmico em ovinos.

Palavras-chave: bem-estar animal; conforto térmico; pecuária de precisão; termografia de infravermelho.

Fuzzy and neuro-fuzzy models for predicting physiological variables in sheep based on micrometeorological data

ABSTRACT: The use of computational models and thermography enables automated systems to monitor thermal comfort in livestock. This study developed fuzzy and neuro-fuzzy models to predict physiological variables in sheep based on micrometeorological variables. Micrometeorological data were collected using a black globe thermometer, while physiological data included rectal temperature and surface temperatures of the eyes, flanks, and ribs. A total of 396 data points were collected from 18 sheep during two daily periods. The models were created in MATLAB, using air temperature and humidity as inputs and physiological data as outputs. Performance evaluation considered statistics such as mean absolute error (MAE), mean absolute percentage error (MAPE), mean squared error (MSE), root mean squared error (RMSE), and Nash-Sutcliffe efficiency index (NSE). The neuro-fuzzy model outperformed the fuzzy model, although both delivered satisfactory results. These models eliminate the need for invasive data collection, save time and human resources, and enable automation with greater precision in thermal stress analysis and animal welfare assessment. The approach proved efficient in estimating physiological variables, contributing to advancements in monitoring thermal comfort in sheep.

Keywords: animal welfare; infrared thermography; precision livestock farming; thermal comfort.

1. INTRODUÇÃO

A avaliação do conforto térmico é realizada pelo monitoramento das respostas fisiológicas ou pelo comportamento dos animais. Contudo, essa observação pode demandar tempo e necessitar de pessoas especializadas para a coleta dos dados, além de ser invasiva e estressante para os animais. Muitos estudos têm utilizado diversas tecnologias

para superar essas dificuldades, especialmente por meio de técnicas de inteligência artificial destinadas a captar padrões comportamentais em ovinos (MANSBRIDGE et al., 2018; FOGARTY et al., 2021; AMORIM et al., 2024; AMORIM et al., 2025).

Outra forma de avaliação do conforto térmico é por meio das variáveis fisiológicas. Essas variáveis fisiológicas podem

demonstrar a adaptação dos animais ao ambiente e seu potencial para produção (ACOSTA-GRANADOS et al., 2025). Ferreira et al. (2023) destacam que a análise dessas variáveis em ovinos é um excelente indicador de desconforto térmico no ambiente. Nesse contexto, uma ferramenta não invasiva que tem sido explorada é a termografia de infravermelho, capaz de captar o calor emitido pela superfície dos animais por meio de câmeras termográficas (PACHECO et al., 2020).

Os dados gerados por sensores infravermelhos podem alimentar modelos preditivos, modelos prescritivos ou algoritmos de inteligência artificial, permitindo a geração de informações e novas abordagens para auxiliar o processo de tomada de decisão por parte de técnicos e produtores rurais em tempo real (GARCIA et al., 2021). Nesse âmbito, o uso de técnicas de inteligência artificial, como a lógica fuzzy e a neuro-fuzzy, tem sido aplicado em diversos segmentos para realização de modelagens (AMORIM et al., 2022; TRABACHINI et al., 2024; SANTOS et al., 2025).

Entretanto, a adoção desses modelos computacionais para a predição de variáveis fisiológicas em sistemas de produção de pequenos ruminantes ainda é bastante limitada. Esse fato ressalta a importância de aprofundar pesquisas sobre o tema, bem como de realizar estudos que demonstrem a aplicação prática dessas tecnologias nos sistemas de produção de ovinos e caprinos (BORGES et al., 2019).

Com base no exposto, este trabalho teve como objetivo prever variáveis fisiológicas de ovinos utilizando lógica fuzzy e neuro-fuzzy, a partir de dados micrometeorológicos e termografia de infravermelho. Essa abordagem apresenta vantagens como a eliminação de coletas invasivas aos animais, a redução do tempo e da necessidade de pessoal especializado para interpretação de dados, a melhoria na acurácia da investigação do estresse térmico por meio da combinação de avaliações micrometeorológicas e fisiológicas e a possibilidade de automação com tecnologias baseadas em modelos computacionais e termografia de infravermelho.

2. MATERIAIS E MÉTODOS

2.1. Local do experimento e características dos animais

O experimento foi conduzido em um aprisco destinado a caprinos e ovinos localizado no Campus de Ciências Agrárias da Universidade Federal do Vale do São Francisco - Univasf, Petrolina-PE, coordenadas 09°19'28"S e 40°33'34"W, com altitude média de 393 m. De acordo com Bonfim et al. (2024), Petrolina apresenta temperatura média de 27,2°C, umidade relativa do ar de 55,8% e precipitação média acumulada de 419,0 mm. Além disso, a região apresenta clima tropical semiárido, tipo BshW, seco e quente, segundo a classificação climática de Köppen-Geiger.

O experimento utilizou 18 ovinos mestiços (Santa Inês x Dorper), machos inteiros, com média de seis meses de idade e oriundos de rebanhos característicos de sistemas de produção da região. Os animais foram identificados e colocados em baias individuais, providas de bebedouros e comedouros. Todo o procedimento realizado durante este experimento foi aprovado pela Comissão de Ética no Uso de Animais (CEUA) da Universidade Federal da Paraíba (UFPB), sob o protocolo CEUA nº 5391070619.

2.2. Característica da instalação

O aprisco utilizado apresentava as seguintes características construtivas: orientação Leste-Oeste, dotado

de piso de cimento, em nível do solo, cobertura com estrutura de aço e telha de cerâmica com inclinação de 25%, pé direito de 3,0 m acrescido de 0,39 m da tesoura e baias individuais de 2,05 x 1,0 m. As paredes das baias eram de alvenaria com 1,30 m de altura. O aprisco era todo cercado por uma mureta de alvenaria com altura de 1,30 m, que ficava a uma distância de 1,50 m das baias nas laterais do aprisco e 2,15 m de distância nas extremidades, formando um corredor interno em volta de todo o aprisco. O local apresentava uma largura de 9,9 m, comprimento de 28,9 m e área total de 286,1 m² (Figura 1).

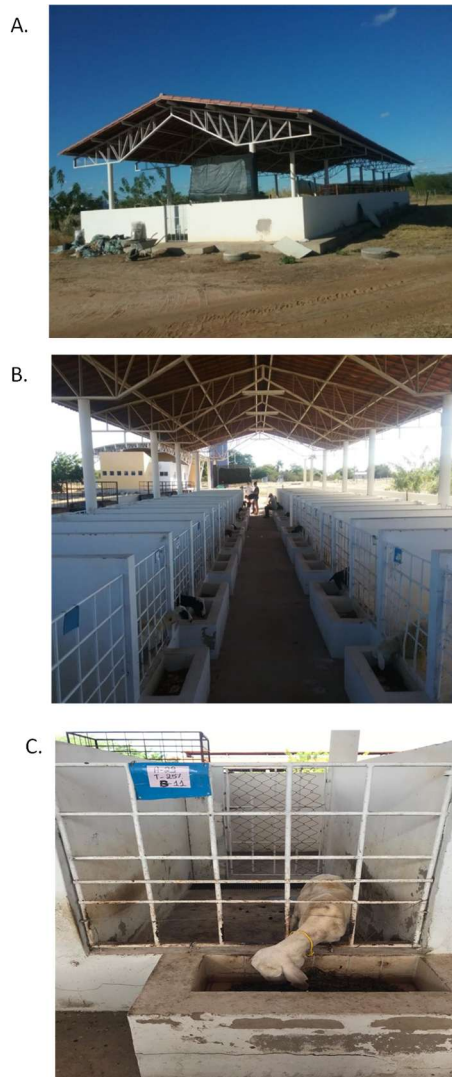


Figura 1. Vista geral (A), corredor entre as baias (B) e baia individual (C).

Figure 1. General view (A), corridor between bays (B) and individual pen (C).

2.3. Coleta de dados

2.3.1. Dados micrometeorológicos

As variáveis micrometeorológicas obtidas foram Temperatura do ar (T_a), Umidade Relativa do Ar (U_r), que foram coletadas em dois horários específicos, às 09:00h e 15:00h, durante o mês de junho de 2021, por 11 dias não consecutivos. Para essas medições foi utilizado o termômetro de Globo Portátil, modelo ITWTG2000 da marca Instruthemp, com faixa de medição de 0 a 80°C / 0 a 100% UR, com resolução de 0,1 °C e de 0,1% Ur.

2.3.2. Variáveis fisiológicas

As variáveis fisiológicas foram Frequência Respiratória (FR), Temperatura Retal (TR) e Temperatura Superficial (TS), também registradas às 9:00 e 15:00 horas, em onze dias não consecutivos ao longo do experimento, representando 396 coletas de dados para cada variável ao todo. A FR foi tomada pela contagem dos movimentos respiratórios em movimentos por minuto controlados pela observação do flanco, contando-se o número de movimentos durante 15 segundos e o valor obtido multiplicado por quatro para se calcular a frequência respiratória por minuto. A TR foi determinada através de um termômetro clínico veterinário, com escala de até 44°C; o termômetro foi introduzido diretamente no reto do animal, com o bulbo junto à mucosa, permanecendo por um período de dois minutos. A TS foi mensurada através de câmera termográfica modelo FLIR-T62101, onde coletaram-se imagens do corpo inteiro no lado esquerdo do animal a uma distância de 2 metros e emissividade 0,95.

As imagens térmicas foram analisadas no software FLIR tools, que forneceu os perfis termográficos dos animais. No software foram analisadas as temperaturas de superfície corporais da região ocular, costela e flanco (Figura 2). As regiões foram escolhidas por se tratar de áreas corporais que favorecem as trocas térmicas, demonstradas em estudos anteriores (MARTELLO et al., 2016; SALLES et al., 2016; SOUSA et al., 2018).

2.4. Modelos para predição das variáveis fisiológicas

Os modelos computacionais baseados em lógica fuzzy e neuro-fuzzy tiveram as variáveis fisiológicas de temperatura retal (TR), temperatura ocular (TO), temperatura superficial costela (TSc) e temperatura superficial flanco (TSf) do animal como as de saída (Variável predita), pois são as variáveis importantes para caracterizar o estado de conforto térmico dos animais. As variáveis escolhidas para comporem a entrada foram as variáveis micrometeorológicas de temperatura do ar (Ta) e umidade relativa do ar (Ur), pois exercem forte influência sobre o desempenho animal.

2.4.1. Desenvolvimento do sistema fuzzy

As proposições fuzzy foram apresentadas na forma se-então, totalizando um conjunto de nove regras (Tabela 1). As

regras foram definidas na forma de sentenças linguísticas com base nos dados coletados experimentalmente e elaboradas com o auxílio de especialistas da área. A metodologia proposta por Cornelissen et al. (2003) e empregada por Yanagi Junior et al. (2012) e Lourençoni et al. (2019) foi aplicada para escolher os especialistas e, considerando que ambas as variáveis de entrada possuem influência no conforto e desempenho dos ovinos, foram atribuídos pesos de fator de ponderação igual a um para todas as regras (AMORIM et al., 2022). O modelo foi elaborado considerando as orientações e os parâmetros de temperatura do ar, umidade relativa, temperatura superficial e temperatura retal apresentados na literatura (MIRANDA et al., 2018; MASCARENHAS et al., 2023).

As curvas de pertinência para as variáveis de entrada e de saída que melhor se ajustaram foram representadas pela curva de pertinência trapezoidal (Figura 3 e Figura 4).

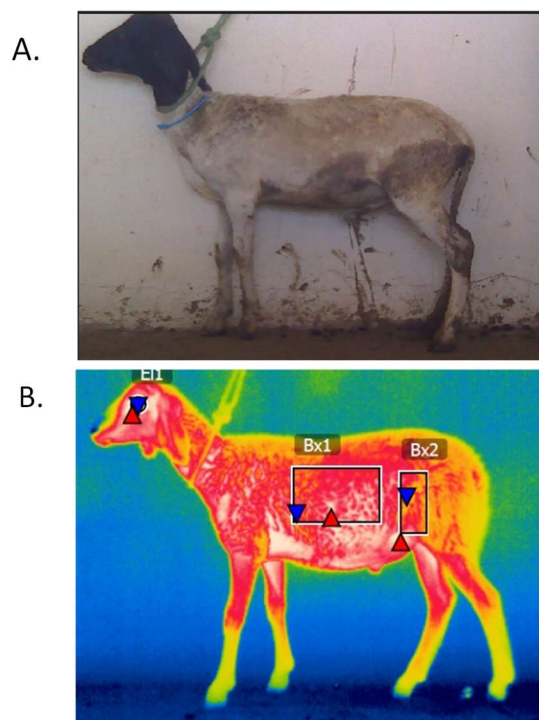


Figura 2. Imagem de luz visível (A) e termograma do animal (B).
Figure 2. Visible light image (A) and thermogram of the animal (B).

Tabela 1. Conjuntos de regras para o modelo fuzzy tendo como variáveis de saída temperatura retal (TR), temperatura ocular (TO), temperatura superficial flanco (TSf) e temperatura superficial costela (TSc).

Table 1. Rule sets for the fuzzy model, with output variables including rectal temperature (TR), ocular temperature (TO), flank surface temperature (TSf), and rib surface temperature (TSc).

Regras	Variável de saída
1	Se (Ta é frio) e (Ur é baixa) então (TR, TO, TSf e TSC é baixa)
2	Se (Ta é frio) e (Ur é ideal) então (TR, TO, TSf e TSC é baixa)
3	Se (Ta é frio) e (Ur é alta) então (TR, TO, TSf e TSC é baixa)
4	Se (Ta é ideal) e (Ur é baixa) então (TR, TO, TSf e TSC é ideal)
5	Se (Ta é ideal) e (Ur é ideal) então (TR, TO, TSf e TSC é ideal)
6	Se (Ta é ideal) e (Ur é alta) então (TR, TO, TSf e TSC é ideal)
7	Se (Ta é calor) e (Ur é baixa) então (TR, TO, TSf e TSC é alta)
8	Se (Ta é calor) e (Ur é ideal) então (TR, TO, TSf e TSC é alta)
9	Se (Ta é calor) e (Ur é alta) então (TR, TO, TSf e TSC é alta)

2.4.2. Desenvolvimento do sistema neuro-fuzzy

Os modelos baseados em neuro-fuzzy também foram desenvolvidos, ajustados e validados a partir do banco de

dados coletado, com temperatura do ar e umidade relativa do ar como as variáveis de entrada, e as variáveis temperatura retal, temperatura ocular, temperatura superficial costela e

temperatura superficial flanco definidas como as de saída, as previstas. Para cada conjunto de dados, três subgrupos (treinamento, validação e teste) foram designados para desenvolver o sistema neuro-fuzzy, sendo 70% do conjunto usado para treinamento e 30% para validação e testes. De um total de 396 conjuntos de dados, 277 dados foram utilizados

para o treinamento da rede e 119 para a validação e testes. O sistema neuro-fuzzy foi derivado do sistema de inferência fuzzy Takagi-Sugeno. Nesse sistema, as disposições de entrada e saída são baseadas em regras, portanto, as respostas foram elaboradas por funções por partes (não fuzzy) (TAKAGI; SUGENO, 1985).




Figura 3. Funções de pertinência para as variáveis de entrada do modelo fuzzy: umidade relativa do ar (A), temperatura do ar (B).
 Figure 3. Membership functions for the input variables of the fuzzy model: air relative humidity (A), air temperature (B).

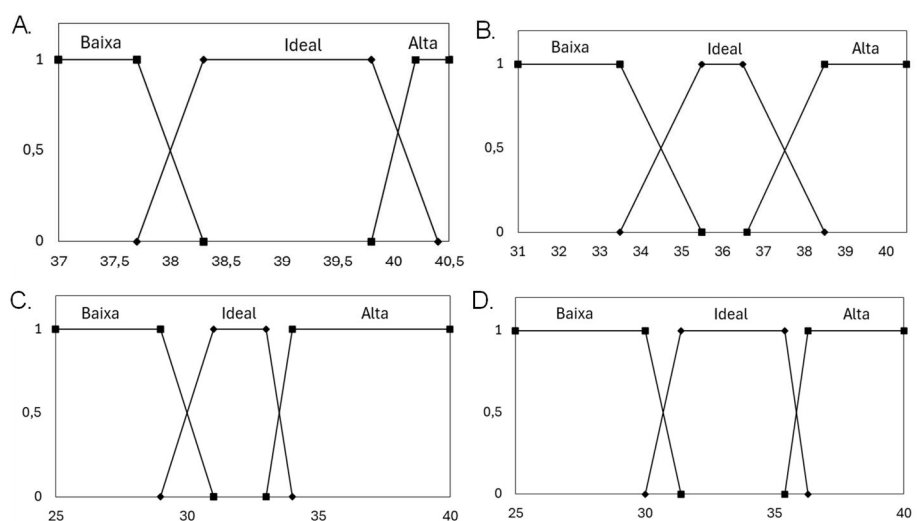


Figura 4. Funções de pertinência para as variáveis de saída do modelo fuzzy: temperatura retal (A), temperatura ocular (B), temperatura superficial flanco (C), temperatura superficial costela (D).
 Figure 4. Membership functions for the output variables of the fuzzy model: rectal temperature (A), ocular temperature (B), flank surface temperature (C), rib surface temperature (D).

2.4.3. Software para desenvolvimento dos modelos

O modelo baseado na lógica fuzzy foi construído utilizando o software MATLAB® 6.5, sendo utilizado o método de inferência fuzzy de Mamdani (AMENDOLA; SOUZA, 2004) que, como resposta, traz um conjunto fuzzy originado da combinação dos valores de entrada com os seus respectivos graus de pertinência através do operador mínimo e em seguida pela superposição das regras por meio do operador máximo. A defuzzificação foi realizada utilizando-se o método do Centro de Gravidade (Centróide ou Centro de Área), que considera todas as possibilidades de saída, transformando o conjunto fuzzy, originado pela inferência, em valor numérico, conforme proposto por Amendola; Souza (2004).

Para o desenvolvimento do modelo e simulação do modelo neuro-fuzzy, também foi utilizado o Matlab. Diferentes configurações foram utilizadas para o desenvolvimento de vários modelos neuro-fuzzy. Os tipos de funções de relevância (Gaussiana, triangular e trapezoidal), número de estações de treinamento e métodos de otimização (retropropagação ou híbrido) foram testados. Com base nos

testes, foi selecionado o modelo com menor erro de treinamento e sem erros internos de saída em seus conjuntos.

2.5. Validação dos modelos

Todos os dados coletados foram organizados na planilha eletrônica. Na etapa da validação, para testar o desempenho dos modelos, foram utilizados alguns indicadores estatísticos tais como: erro médio absoluto (MAE); erro percentual absoluto médio (MAPE); erro quadrático médio (MSE); raiz do erro quadrático médio (RMSE); índice de eficiência (NSE) desenvolvido por Nash; Sutcliffe (1970) e gráfico de distribuição dos resíduos.

Estes índices servem, então, para avaliar o desempenho do modelo estimado, através da comparação entre os dados medidos e os previstos pelo modelo fuzzy e neuro-fuzzy. Estes indicadores de desempenhos são definidos pelas equações de 1 a 5:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Pi - Oi| \tag{01}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Oi - Pi}{Oi} \right| * 100 \tag{02}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2 \quad (03)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (04)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (05)$$

em que: P_i é o valor predito pelo modelo; O_i é o valor observado; n é o número total de elementos e \bar{O} é a média dos valores observados.

Os modelos que apresentam melhores desempenhos são aqueles com os menores valores de erro médio absoluto (MAE), erro quadrático médio (MSE) e raiz do erro quadrático médio (RMSE). Esses índices são frequentemente usados na verificação da acurácia dos modelos numéricos; os valores devem ser mais próximos de zero possível (HALLAK; PEREIRA FILHO, 2011).

O erro percentual absoluto médio (MAPE) é calculado através da diferença entre valores estimados e reais e equivale às previsões, quanto menor for o MAPE, melhor será a adequação do modelo, e consequentemente, a previsão. O índice de eficiência de Nash-Sutcliffe (NSE) é uma estatística normalizada que determina a magnitude relativa da variância residual quando comparado com a variação dos dados de medição. O índice varia entre $-\infty$ e 1, e quanto maior o valor, melhor a performance do modelo (SIRQUEIRA et al., 2022).

Além disso, a análise gráfica dos resíduos é fundamental na determinação de um modelo, mesmo que as medias de precisão do ajustamento sejam boas indicadoras, visto que podem ocorrer erros tendenciados em algumas amplitudes de classes na variável resposta (CAMPOS et al., 2013). Os resíduos consistem na distribuição dos valores amostrais

calculados com a diferença entre o observado e o estimado do método preditivo.

3. RESULTADOS

Os índices estatísticos de validação e ajustes dos modelos fuzzy e neuro-fuzzy para temperatura retal (TR), temperatura ocular (TO), temperatura superficial flanco (TSF) e temperatura superficial costela (TSC) são mostrados na Tabela 4.

A Figura 6 apresenta o gráfico de distribuição dos resíduos das variáveis de saída obtidos através do modelo fuzzy. A Figura 7 apresenta o gráfico de distribuição dos resíduos das variáveis de saída obtidos através do modelo neuro-fuzzy. Nos gráficos de resíduos dos modelos fuzzy, observa-se que a estimativa da temperatura retal (Figura 6A) foi a mais precisa, pois apresentou menor amplitude de resíduos, além de uma distribuição bem equilibrada e homogênea. Na estimativa da temperatura ocular e da temperatura superficial do flanco (Figuras 6B e 6C, respectivamente), os modelos exibiram boa distribuição dos dados e variação homogênea, embora tenham sido identificados alguns pontos outliers. Por outro lado, na estimativa da temperatura superficial da costela (Figura 6D), o modelo foi menos preciso, apresentando maior amplitude dos resíduos e uma tendência à subestimação.

Nos gráficos de resíduos dos modelos neuro-fuzzy, destaca-se que o modelo mais preciso foi na estimativa da temperatura retal (Figura 7A), que apresentou menor amplitude de resíduos e uma variação homogênea dos dados. Na estimativa da temperatura superficial da costela (Figura 7D), o modelo também apresentou tendência à subestimação.

Tabela 4. Índices estatísticos para verificação da acurácia dos modelos fuzzy e neuro-fuzzy para a temperatura retal (tr), temperatura ocular (to), temperatura superficial flanco (tsf) e temperatura superficial costela (tsc).
Table 4. Statistical indices for verifying the accuracy of the fuzzy and neuro-fuzzy models for rectal temperature (tr), ocular temperature (to), flank surface temperature (tsf) and rib surface temperature (tsc).

Variáveis	Índices de desempenho									
	MAE		MSE		RSME		MAPE		NSE	
	Fuzzy	Neuro-Fuzzy	Fuzzy	Neuro-Fuzzy	Fuzzy	Neuro-Fuzzy	Fuzzy	Neuro-Fuzzy	Fuzzy	Neuro-Fuzzy
TR	0,36	0,30	0,21	0,15	0,46	0,38	0,92	0,76	0,04	0,27
TO	0,84	0,57	1,07	0,53	1,03	0,73	2,31	1,58	0,88	0,94
TSf	1,53	1,11	3,81	2,24	1,95	1,50	4,81	3,52	0,92	0,96
TSc	1,87	1,06	5,87	1,78	2,42	1,33	6,04	3,34	0,87	0,96

Legenda: MAE - erro médio absoluto; MSE - erro quadrático médio; RMSE - raiz do erro quadrático médio; MAPE - erro percentual absoluto médio; NSE - índice de eficiência Nash-Sutcliffe.

Legend: MAE - mean absolute error; MSE - mean squared error; RMSE - root mean squared error; MAPE - mean absolute percentage error; NSE - Nash-Sutcliffe efficiency index.

4. DISCUSSÃO

Os valores de MAE, MSE e RMSE são índices amplamente utilizados para verificar a acurácia de modelos numéricos. Modelos com melhor desempenho apresentam valores mais próximos de zero. No modelo fuzzy, os valores de MAE, MSE e RMSE entre os dados observados e previstos foram ligeiramente maiores para as variáveis de temperatura superficial do flanco (1,53, 3,81 e 1,95) e da costela (1,87, 5,87 e 2,42), em comparação com as outras variáveis estimadas. Ainda assim, esses valores foram inferiores aos encontrados por Brito et al. (2022), que desenvolveram um modelo fuzzy para prever parâmetros agrônomicos em mudas de pimentão sob diferentes intensidades luminosas e relataram valores de MAE, MSE e

RMSE de 3,267, 13,901 e 138,6, respectivamente, indicando que os resultados do presente estudo foram satisfatórios.

No modelo neuro-fuzzy, a predição das variáveis também apresentou bom desempenho, com valores de MAE, MSE e RMSE próximos de zero. Os índices variaram entre 0,30 e 1,11, 0,15 e 2,24 e 0,38 e 1,50, respectivamente, sendo os menores valores observados na variável temperatura retal (MAE: 0,30, MSE: 0,15 e RMSE: 0,38). Comparativamente, Pacheco et al. (2020), ao desenvolverem um modelo computacional baseado em redes neurais artificiais para prever a temperatura retal de vacas holandesas, relataram valores de MSE e RMSE de 0,31 e 0,40, respectivamente. O presente estudo, entretanto, obteve um MSE inferior, reforçando a precisão do modelo proposto.

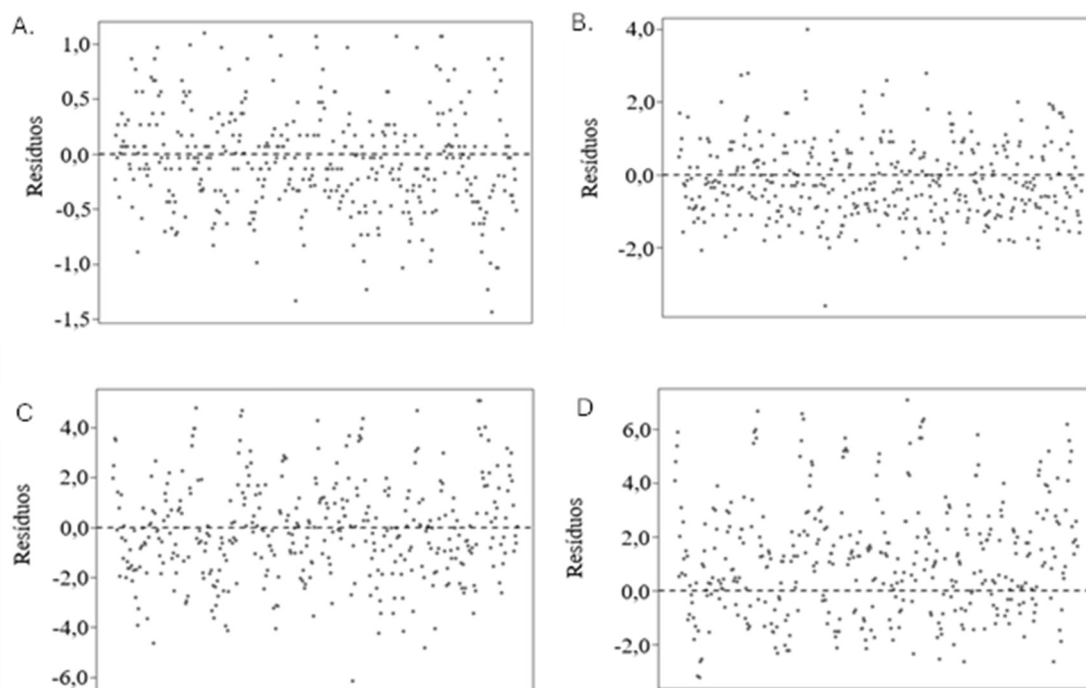


Figura 6. Distribuição dos resíduos das variáveis de saída do modelo fuzzy: (A) temperatura retal, (B) temperatura ocular, (C) temperatura superficial flanco, (D) temperatura superficial costela.

Figure 6. Distribution of the residuals of the output variables of the fuzzy model: (A) rectal temperature, (B) ocular temperature, (C) flank surface temperature, (D) rib surface temperature.

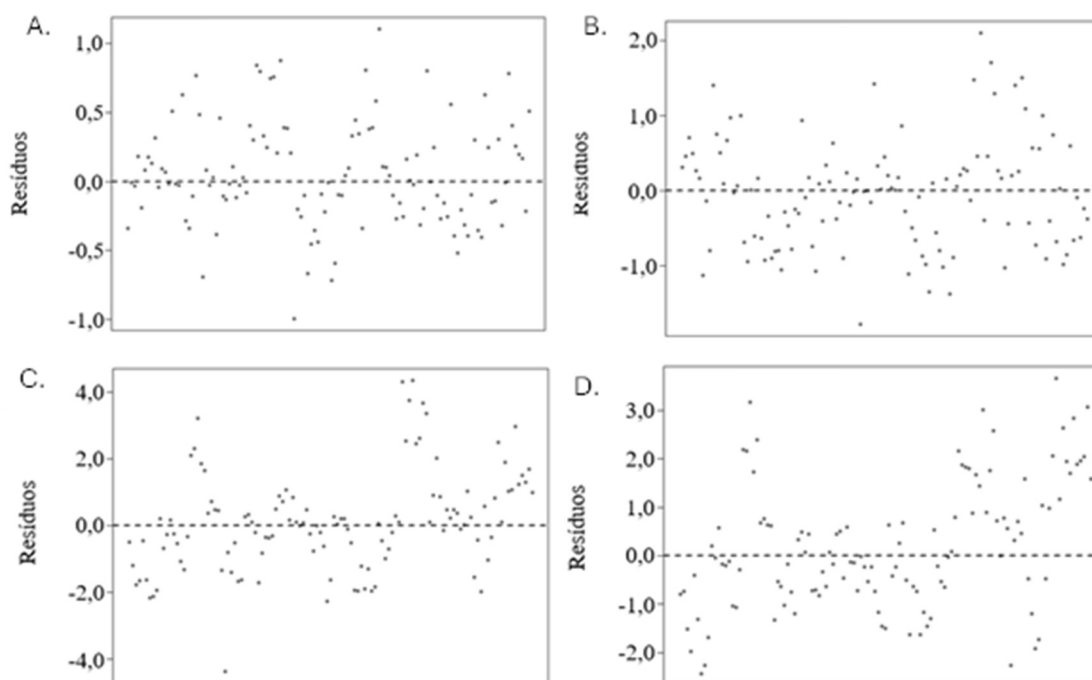


Figura 7: Distribuição dos resíduos das variáveis de saída do modelo neuro-fuzzy: temperatura retal (A), temperatura ocular (B), temperatura superficial flanco (C), temperatura superficial costela (D).

Figure 7: Distribution of residuals of the output variables of the neuro-fuzzy model: rectal temperature (A), ocular temperature (B), flank surface temperature (C), rib surface temperature (D).

O MAPE, calculado pela diferença entre valores estimados e reais, é um indicador que reflete a adequação do modelo, sendo que valores menores indicam melhores previsões. No modelo fuzzy, o MAPE variou de 0,92% a 6,04%, enquanto no modelo neuro-fuzzy os valores oscilaram entre 0,76% e 3,52%, demonstrando boa acurácia. Para a estimativa da temperatura retal, o MAPE foi de 0,92%,

menor do que o valor de 1,29% encontrado por Leite et al. (2022) em um estudo com ovinos da raça Morada Nova. No entanto, para as temperaturas superficiais do flanco e da costela, o modelo fuzzy apresentou MAPE de 4,81% e 6,04%, respectivamente, enquanto o modelo neuro-fuzzy obteve valores de 3,52% e 3,34%. Esses valores são superiores aos de Leite et al. (2022), que relataram MAPE de

2,70% para a estimativa de temperatura superficial de ovinos. Essa diferença pode ser atribuída à heterogeneidade dos dados no presente estudo, que incluiu ovinos mestiços, ao contrário do grupo mais homogêneo de animais analisado por Leite et al. (2022).

Adicionalmente, Lins et al. (2021), ao utilizarem a lógica neuro-fuzzy para prever a temperatura ocular de galinhas poedeiras, relataram MAPE de 2,90%. Esses valores são próximos aos obtidos neste estudo, que foram de 2,31% para o modelo fuzzy e 1,58% para o modelo neuro-fuzzy.

O índice de eficiência de Nash-Sutcliffe (NSE) variou de 0,04 a 0,92 no modelo fuzzy e de 0,27 a 0,96 no modelo neuro-fuzzy. Esse índice, que mede a magnitude relativa da variância residual em comparação com a variância dos dados medidos, indica melhor desempenho quanto mais próximo de 1. Com exceção da variável temperatura retal, todos os valores de NSE no presente estudo ficaram próximos de 1, refletindo boa eficiência dos modelos. Brito et al. (2022) relataram valores de NSE entre 0,65 e 0,99, corroborando os achados deste estudo.

Embora os estudos de Lins et al. (2021) e Brito et al. (2022) não tenham sido conduzidos com ovinos, ambos empregaram as mesmas métricas estatísticas e modelos de predição baseados em lógica fuzzy ou neuro-fuzzy, o que permite uma comparação indireta do desempenho obtido no presente trabalho. Essa abordagem possibilita contextualizar a magnitude dos erros encontrados, mesmo que as variáveis de saída e as espécies estudadas sejam distintas, uma vez que o foco da comparação recai sobre a eficácia das técnicas de modelagem utilizadas. Assim, os valores observados para ovinos neste estudo puderam ser interpretados à luz de faixas de erro previamente reportadas na literatura, reforçando a adequação e o potencial de aplicação dos modelos propostos.

Além disso, a importância desses resultados reside no potencial de aplicação prática dos modelos fuzzy e neuro-fuzzy em sistemas de monitoramento automatizado de variáveis fisiológicas em animais de produção. Esses modelos podem ser integrados em sistemas de pecuária de precisão, promovendo um manejo mais eficiente, redução de custos operacionais e melhoria do bem-estar animal. Além disso, sua capacidade de prever com alta acurácia diferentes variáveis em condições micrometeorológicas variáveis demonstra seu valor como ferramenta para otimizar o desempenho produtivo e mitigar os efeitos do estresse térmico em rebanhos heterogêneos.

5. CONCLUSÕES

Os modelos fuzzy e neuro-fuzzy propostos permitiram estimar, com eficiência, a temperatura retal, temperatura ocular, temperatura superficial flanco e temperatura superficial costela de ovinos em função da temperatura do ar e da umidade relativa do ar. Esses modelos proporcionaram baixos valores nos erros, bons índices de eficiência e distribuição de resíduos homogêneos, com o modelo neuro-fuzzy apresentando melhores resultados quando comparado ao fuzzy.

Assim, os modelos estimados podem ser utilizados como ferramenta de controle do ambiente térmico em instalações comerciais de produção, oferecendo vantagens como a eliminação de coletas invasivas, redução de tempo e recursos humanos, além de permitir a automação do processo por meio de modelos computacionais e termografia. Essa abordagem proporciona maior acurácia na análise do estresse térmico e do bem-estar animal.

6. REFERÊNCIAS

- ACOSTA-GRANADOS, I. C.; CARRERO-FLORES, J. E.; VIDAURRE, R. A.; CRUZ-LUIS, J. A.; RUÍZ-CHAMORRO, J. A. Morphometric and phaneroptic characteristics of creole goats in the dry forest of Peru. *Nativa*, v. 13, n. 1, p. 156-161, 2025. <https://doi.org/10.31413/nat.v13i1.18865>
- AMENDOLA, M.; SOUZA, A. L. **Manual do uso da teoria dos conjuntos fuzzy no matlab 6.1**. Campinas: Faculdade de Engenharia Agrícola, UNICAMP, 2004. 30p.
- AMORIM, M.; COSTA, D.; HARADA, É.; SILVA, W. P.; TURCO, S. H. N. Performance of electronic device and different visual observation intervals in assessing feeding behavior in sheep. *Computers and Electronics in Agriculture*, v. 231, e110053, 2025. <https://doi.org/10.1016/j.compag.2025.110053>
- AMORIM, M. D. N.; MIRANDA, I. B. SANTOS, Í. E. D. A. LOURENÇONI, D.; TURCO, S. H. Fuzzy modeling for rapid cooling of table grapes in different plastic film bags. *Engenharia Agrícola*, v. 42, n. 1, e20200149, 2022. <https://doi.org/10.1590/1809-4430-Eng.Agric.v42n1e20200149/2022>
- AMORIM, M. N.; TURCO, S. H. N.; DOS SANTOS COSTA, D.; FERREIRA, I. J. S.; DA SILVA, W. P.; SABINO, A. L. C.; DA SILVA-MIRANDA, K. O. Discrimination of ingestive behavior in sheep using an electronic device based on a triaxial accelerometer and machine learning. *Computers and Electronics in Agriculture*, v. 218, e108657, 2024. <https://doi.org/10.1016/j.compag.2024.108657>
- BONFIM, O. C.; AMORIM, M. N.; TURCO, S. H. N.; OLIVEIRA, P. T. L.; GONÇALVES, I. C. M.; QUEIROZ, L. C. R.; FIGUEIREDO, L. B. F. Variabilidade espacial do ambiente térmico e da iluminação em instalação para frangos de corte em região semiárida. *Nativa*, v. 12, n. 4, p. 631-641, 2024. <https://doi.org/10.31413/nat.v12i4.17457>
- BORGES, L. S.; ROCHA, F. S. B.; NERI, V. S.; MAIA, F. S. P.; CASTRO, O. C. C.; CAMPELO, J. E. G.; SARMENTO, J. L. R. Gestão zootécnica e genética informatizadas em pequenos ruminantes: uma revisão. *Medicina Veterinária*, v. 13, n. 2, p. 251-257, 2019. <https://doi.org/10.26605/medvet-v13n2-3083>
- BRITO, D. C.; LOURENÇONI, D.; TURCO, S. H.; OLIVEIRA, P. T. Fuzzy modeling for the analysis of different light intensities in the production of bell pepper seedlings. *Engenharia Agrícola*, v. 42, n. 3, e20220041, 2022. <https://doi.org/10.1590/1809-4430-Eng.Agric.v42n3e20220041/2022>
- CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal: Perguntas e Respostas**. 4. ed. Viçosa: UFV, 2013. 605p.
- CORNELISSEN, A. M. G.; VAN DEN BERG, J.; KOOPS, W. J.; KAYMAK, U. Elicitation of expert knowledge for fuzzy evaluation of agricultural production systems. *Agriculture, Ecosystems & Environment*, v. 95, n. 1, p. 1-18, 2003. [https://doi.org/10.1016/S0167-8809\(02\)00174-3](https://doi.org/10.1016/S0167-8809(02)00174-3)
- FERREIRA, J.; MCMANUS, C. M.; SILVEIRA, R. M. F.; SILVA, W. S. T. da; GUILHERMINO, M. M.; ASENSIO, L. A. B.; BOZZI, R.; FAÇANHA, D. A. E. Reference patterns for thermoregulation in Italian Massese ewes. *Journal of Thermal Biology*, v. 113,


- e103483, 2023. <https://doi.org/10.1016/j.jtherbio.2023.103483>
- FOGARTY, E. S.; SWAIN, D. L.; CRONIN, G. M.; MORAES, L. E.; BAILEY, D. W.; TROTTER, M. Developing a simulated online model that integrates GNSS, accelerometer and weather data to detect parturition events in grazing sheep: a machine learning approach. *Animals*, v. 11, n. 2, e303, 2021. <https://doi.org/10.3390/ani11020303>
- GARCIA, A. R.; MOURA, A. B. B.; DO NASCIMENTO BARRETO, A.; DE ANDRADE PANTOJA, M. H.; DE SOUSA, M. A. P.; JUNIOR, R. J. M. Estresse calórico e reprodução em ovinos: fundamentos e perspectivas tecnológicas. *Revista Brasileira de Reprodução Animal*, v. 45, n. 4, p. 430-442, 2021. <https://doi.org/10.21451/1809-3000.RBRA2021.058>
- HALLAK, R.; PEREIRA FILHO, A. J. Metodologia para análise de desempenho de simulações de sistemas convectivos na região metropolitana de São Paulo com o modelo ARPS: sensibilidade a variações com os esquemas de advecção e assimilação de dados. *Revista Brasileira de Meteorologia*, v. 26, n. 4, p. 591-608, 2011. <https://doi.org/10.1590/S0102-77862011000400009>
- LEITE, P. G.; CUNHA, B. B.; SOUSA, W. S.; MARQUES, J. I.; FURTADO, D. A.; MACHADO, N. A. F. Modelagem fuzzy das respostas fisiológicas e de desempenho de ovinos sob estresse térmico e salino. In: MARQUES, J. I.; MACHADO, N. A. F.; CUNHA, B. B.; SOUSA, W. S.; ALMEIDA, E. I. B. *Pesquisas em ambiência animal*. São Luís: Edufma, 2022. p. 5-18.
- LINS, A. C. S.; SOUZA, I. J.; LOURENÇONI, D.; YANAGI JÚNIOR, T.; SANTOS, I. E. dos A. Fuzzy logic modeling of the ocular temperature of cattle in thermal stress conditions. *Engenharia Agrícola*, v. 41, n. 4, p. 418-426, 2021. <https://doi.org/10.1590/1809-4430-Eng.Agric.v41n4p418-426/2021>
- LOURENÇONI, D.; ABREU, P. G. D.; YANAGI, T.; CAMPOS, A. T.; YANAGI, S. D. N. Pertinence curves in fuzzy modeling of the productive responses of broilers. *Engenharia Agrícola*, v. 39, n. 3, p. 265-271, 2019. <https://doi.org/10.1590/1809-4430-Eng.Agric.v39n3p265-271/2019>
- MANSBRIDGE, N.; MITSCH, J.; BOLLARD, N.; ELLIS, K.; MIGUEL-PACHECO, G. G.; DOTTORINI, T.; KALER, J. Feature selection and comparison of machine learning algorithms in classification of grazing and rumination behaviour in sheep. *Sensors*, v. 18, n. 10, e3532, 2018. <https://doi.org/10.3390/s18103532>
- MARTELLO, L. S.; LUZ E SILVA, S. da; GOMES, R. da C.; CORTE, R. R. P. da S.; LEME, P. R. Infrared thermography as a tool to evaluate body surface temperature and its relationship with feed efficiency in Bos indicus cattle in tropical conditions. *International Journal of Biometeorology*, v. 60, p. 173-181, 2016. <https://doi.org/10.1007/s00484-015-1015-9>
- MASCARENHAS, N. M. H.; FURTADO, D. A.; FONSÊCA, V. D. F. C.; SOUZA, B. B. de; OLIVEIRA, A. G. de; MORAIS, F. T. L.; SILVA, R. S.; SILVA, M. R.; BATISTA, L. F.; DORNELAS, K. C.; BEZERRA, C. V. C.; SILVA, J. A. P. da C. Thermal stress index for native sheep. *Journal of Thermal Biology*, v. 115, e103607, 2023. <https://doi.org/10.1016/j.jtherbio.2023.103607>
- MIRANDA, J. R.; SILVA, V. C. da; NETO, J. P. L.; NASCIMENTO, J. W. B. do; ARAUJO, T. G. P. Variáveis fisiológicas e desempenho produtivo como indicadores de estresse térmico em caprinos mestiços Boer em câmara climática. *Energia na Agricultura*, v. 33, n. 3, p. 201-206, 2018. <https://doi.org/10.17224/EnergAgric.2018v33n3p201-206>
- NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models. Part I—A discussion of principles. *Journal of Hydrology*, v. 10, n. 3, p. 282-290, 1970. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- PACHECO, V. M.; SOUSA, R. V. de.; RODRIGUES, A. V. da S.; SARDINHA, E. J. de S.; MARTELLO, L. S. Thermal imaging combined with predictive machine learning based model for the development of thermal stress level classifiers. *Livestock Science*, v. 241, p. 104-244, 2020. <https://doi.org/10.1016/j.livsci.2020.104244>
- SALLES, M. S. V.; SILVA, S. C. da; SALLES, F. A.; ROMA JR, L. C.; EL FARO, L.; MAC LEAN, P. A. B.; OLIVEIRA, C. E. L. de; MARTELLO, L. S. Mapping the body surface temperature of cattle by infrared thermography. *Journal of Thermal Biology*, v. 62, p. 63-69, 2016. <https://doi.org/10.1016/j.jtherbio.2016.10.003>
- SANTOS, Í. E. D. A.; OKITA, W. M.; LOURENÇONI, D.; AMORIM, M. D. N.; DE SÁ SILVA LINS, A. C.; MIRANDA, I. B.; TURCO, S. H. N. Neuro-fuzzy modeling of pulp temperature in rapid cooling chamber. *Journal of Food Science and Technology*, v. 62, p. 1110-1115, 2025. <https://doi.org/10.1007/s13197-024-06109-7>
- SIRQUEIRA, E. S.; ALMEIDA, F. T. de; ARAÚJO, H. B.; ZOLIN, C. A.; CARVALHO, G. A.; PAULISTA, R. S. D.; SILVA, A. F.; BORELLA, D. R. Vazão líquida, sedimentos em suspensão e turbidez na microbacia do rio Caiabi, no ecotóno Cerrado-Amazônia. *Nativa*, v. 10, n. 4, p. 525-532, 2022. <https://doi.org/10.31413/nativa.v10i4.13961>
- SOUSA, R. V. de.; RODRIGUES, A. V. da S.; ABREU, M. G. de; TABILE, R. A.; MARTELLO, L. S. Predictive model based on artificial neural network for assessing beef cattle thermal stress using weather and physiological variables. *Computers and Electronics in Agriculture*, v. 144, p. 37-43, 2018. <https://doi.org/10.1016/j.compag.2017.11.033>
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 15, n. 1, p. 116-132, 1985. <https://doi.org/10.1109/TSMC.1985.6313399>
- TRABACHINI, A.; DIAS, C. S.; MOREIRA, M. R.; WEN, T. C.; CANEPPELE, F. L.; HARADA, É. S.; AMORIM, M. N.; MIRANDA, K. O. S. Automation to improve pig welfare using fuzzy logic. *Revista Brasileira de Ciências Agrárias*, v. 19, n. 3, e3532, 2024. <https://doi.org/10.5039/agraria.v19i3a3532>
- YANAGI JUNIOR, T.; SCHIASSI, L.; ABREU, L. H.; BARBOSA, J. A.; CAMPOS, A. T. Procedimento fuzzy aplicado à avaliação da insalubridade em atividades agrícolas. *Engenharia Agrícola*, v. 32, n. 3, p. 423-434, 2012. <https://doi.org/10.1590/S0100-69162012000300002>

Agradecimentos: O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Contribuições dos autores: R.R.F.S.: metodologia, investigação ou coleta de dados, análise estatística, validação, redação (original); S.H.N.T.: conceitualização, metodologia, obtenção de financiamento, administração ou supervisão, redação (revisão e edição); D.L.: conceitualização, obtenção de financiamento, metodologia, análise estatística, redação (revisão e edição); P.T.L.O.: metodologia, administração ou supervisão, redação (revisão e edição); H.C.B.: análise estatística, validação, metodologia; O.C.B.: investigação ou coleta de dados, validação, redação (revisão e edição); L.B.F.F.: investigação ou coleta de dados, metodologia, validação; M.L.S.A.F.: investigação ou coleta de dados, metodologia, redação (revisão e edição); L.C.R.Q.: investigação ou coleta de dados, validação; M.N.A.: conceitualização, validação, redação (revisão e edição). Todos os autores leram e concordaram com a versão publicada do manuscrito.

Disponibilidade de dados: Os dados desta pesquisa poderão ser obtidos via e-mail, mediante solicitação ao autor correspondente ou ao segundo autor.

Conflito de interesses: Os autores declaram não haver conflitos de interesses.



Copyright: © 2025 by the authors. This article is an Open-Access article distributed under the terms and conditions of the Creative Commons **Attribution-NonCommercial (CC BY-NC)** license (<https://creativecommons.org/licenses/by/4.0/>).