



## Prognóstico anual de la carga térmica radiante aplicándose inteligencia artificial

Pedro Hurtado de Mendoza BORGES<sup>1\*</sup>, Zaíra Morais dos Santos Hurtado de MENDOZA<sup>1</sup>,  
Pedro Hurtado de Mendoza MORAIS<sup>1</sup>

<sup>1</sup>Universidade Federal de Mato Grosso, Cuiabá, MT, Brasil.

\*E-mail: [pborges@ufmt.br](mailto:pborges@ufmt.br)

(Orcid: 0000-0001-7603-8775; 0000-0002-0930-7928; 0000-0003-2431-9262)

Recebido em 16/04/2020; Aceito em 24/06/2021; Publicado em 12/07/2021.

**RESUMEN:** En este estudio se desarrollaron redes neuronales artificiales para predecir el confort térmico animal, en función de la temperatura ambiente y la velocidad del aire para cada día del año en el calendario juliano. Los datos fueron obtenidos en el sitio del Instituto Nacional de Meteorología para una serie histórica de 30 años, coleccionada en la Estación Convencional Padre Ricardo Remetter, municipio de Santo Antonio de Leverger-MT. Para la elaboración de las redes se adoptó como variable de entrada el día del año y como variable de salida la carga térmica de radiación. El número de neuronas varió entre 2 y 15, utilizándose una y dos capas ocultas. El ajuste de las redes se verificó por el coeficiente de determinación, error absoluto medio, porcentaje medio del error absoluto, la normalidad de los residuos y la prueba de t-Student. No hubo discrepancias entre los valores estimados por las redes y los obtenidos de la serie histórica. Finalmente se seleccionaron diez arquitecturas con adecuados índices de desempeño y las cuatro mejores se sometieron al análisis de residuos. Se concluyó que las redes neuronales del tipo perceptron con dos capas ocultas fueron apropiadas para pronosticar la carga térmica radiante, conforme el día Juliano.

**Palabras-clave:** confort térmico; red neuronal artificial; series temporales.

## Annual prognostic of the radiant thermal using artificial intelligence

**ABSTRACT:** In this research, artificial neural networks were developed to predict the animal thermal comfort based on the room temperature and air velocity for the year day in the Julian calendar. The data were obtained from the website of the National Institute of Meteorology for a 30-year historical series, collected at the Padre Ricardo Remetter Meteorological Station, municipality of Santo Antônio de Leverger-MT. To elaborate the networks, the day of the year was adopted as the input variable and the radiation thermal load as the output variable. The number of neurons ranged varied from 2 to 15, being used one and two hidden layers. The adjustment of the networks was verified by the determination coefficient, mean absolute error, mean percentage of the absolute error, the normality of residues and the t-Student test. The values estimated by the networks and those obtained from the historical series did not differ. Finally, ten architectures with adequate performance and efficiency indexes were selected and among them the four best were submitted to the residue analysis. It was concluded that the artificial perceptron neural networks formed by two-layer hidden were suitable for the prognosis of the radiant thermal load, as a function of Julian day.

**Keywords:** thermal comfort; artificial network; time series.

### 1. INTRODUCCIÓN

Entre otros criterios, el confort térmico ha sido muy utilizado para evaluar el bien estar animal, pues posibilita identificar las condiciones ambientales de su alojamiento. Diversos estudios han constatado reducción significativa en el desempeño productivo y reproductivo de los animales debido al estrés térmico (COUTINHO et al., 2014; NAVAS et al., 2016; NETO; BITTAR, 2018). El grado de estrés térmico del animal se puede acentuar por la influencia de las variables climáticas temperatura y humedad del aire, bien como de la velocidad del viento. Además, de los índices de confort propuestos por otros autores, Esmay (1982) sugirió utilizar la carga térmica radiante (CTR) como índice para evaluar las condiciones ambientales en que los animales se alojan.

La carga térmica radiante es la radiación total recibida por un cuerpo, proveniente de todo el espacio circundante. Ese

índice es función de la temperatura ambiente, de la velocidad del viento y de la temperatura de globo negro. Las dos primeras variables pueden ser obtenidas fácilmente en bancos de datos del Instituto Nacional de Meteorología (INMET). Sin embargo, la temperatura del globo negro no siempre es posible su adquisición de forma directa en esas bases de datos. Con el propósito de mejorar las mediciones de temperatura, Abreu et al. (2011) ajustaron un modelo lineal con error en la predicción de 3,19% para estimar la temperatura del globo negro a partir de la temperatura de bulbo seco, la cual está disponible en bancos de datos.

Actualmente, la inteligencia artificial está cada vez más revolucionando la era moderna. En ese sentido, se puede constatar la aplicación de redes neuronales artificiales para estimar variables y modelar procesos con base en valores conocidos. Los mencionados recursos computacionales se

han mostrado como una óptima alternativa para auxiliar en la tomada de decisión del sector agropecuario. Santos et al. (2016) monitorearon el comportamiento de cerdos usando esos modelos, obteniendo resultados precisos y confiables.

Pandorfi et al. (2011) elaboraron redes neuronales para predecir índices zootécnicos durante las fases de gestación y maternidad en la ganadería porcina. Ferraz et al. (2014) desarrollaron redes neuronales artificiales para estimar la masa corporal de polluelos, sometidos a diversos períodos e intensidades de estrés térmico. Aún, Valente et al. (2014) utilizaron ese modelaje para clasificar muestras de leche alteradas por la adición del suero de queso. En los estudios citados, se adoptaron las redes neuronales artificiales del tipo perceptron de varias capas, pudiéndose demostrar la viabilidad de su aplicación y su habilidad para prever informaciones.

Los trabajos consultados permiten inferir que las redes neuronales constituyen un artificio computacional útil en el procesamiento de datos meteorológicos y que su uso es promisor para estimar la carga térmica de radiación, basándose en informaciones climáticas de series históricas disponibles en los bancos de datos del Instituto Nacional de Meteorología. Así, esta investigación fundamentase en la hipótesis de que esos modelos pueden proporcionar los criterios necesarios para predecir la situación del ambiente térmico en instalaciones zootécnicas, auxiliando la tomada de decisión con el propósito de realizar el manejo adecuado de los animales. Esta problemática motivó la elaboración del presente estudio, que tiene como objetivo verificar si las redes neuronales son apropiadas para el pronóstico anual de la carga térmica de radiación, en función de las variables temperatura del bulbo seco y velocidad del aire.

## 2. MATERIAL Y MÉTODOS

### 2.1. Caracterización del área

Las instalaciones zootécnicas seleccionadas para esta investigación pertenecen al Campo Experimental de la Facultad de Agronomía y Zootecnia, Universidad Federal de Mato Grosso. El área está localizada en el municipio de Santo Antônio de Leverger-MT. El clima tropical de la región fue clasificado como Aw (PEEL et al., 2007). La temperatura media anual y la pluviosidad media anual son, respectivamente, 26,1°C y 1267 mm (INMET, 2020).

### 2.2. Colecta de los datos

Los datos colectados correspondieron a la Estación Meteorológica Convencional Padre Ricardo Remetter, código OMM 83364, operando desde 01/01/1986, situada en el municipio de Santo Antônio de Leverger-MT, latitud de -15,7833°, longitud de -56,0667° y altitud de 140 m. En este estudio se utilizaron los valores de la temperatura del bulbo seco y de la velocidad del viento para una serie histórica de 30 años, referentes al período entre 01/01/1988 y 31/12/2018 en los horarios de 00:00, 12:00 y 18:00 horas, disponibles en el Banco de Datos Meteorológicos para la Enseñanza e Investigación (BDMEP), Instituto Nacional de Meteorología (INMET, 2020).

### 2.3. Análisis de los datos

Los datos fueron almacenados em archivos textos y planillas electrónicas. Con las funciones estadísticas, bien como con las herramientas de filtro y clasificación de las planillas, se determinaron los valores de la carga térmica de

radiación (CTR) para cada día del año, en el calendario juliano. Ese índice fue estimado utilizándose la expresión sugerida por Esmay (1982), conforme la ecuación 1.

$$CTR = \alpha \cdot TRM^4 \quad (01)$$

en que: CTR = carga térmica de radiación, en W/m<sup>2</sup>;  $\alpha$  = constante de Stefan-Boltzmann 5,67x10<sup>-8</sup>, en W/m<sup>2</sup>K<sup>4</sup>; TRM = temperatura media radiante, en K.

La temperatura media radiante fue determinada, de acuerdo con la ecuación 2.

$$TRM = 100 \cdot \left[ 2,51 \cdot \sqrt{v} \cdot (T_{gn} - T_{bs}) + \left( \frac{T_{gn}}{100} \right)^{0,25} \right] \quad (02)$$

en que: TRM = temperatura media radiante, en K; v = velocidad del viento, en m/s; T<sub>bs</sub> = temperatura del bulbo seco, en K; T<sub>gn</sub> = temperatura del globo negro, en K.

La temperatura del globo negro fue estimada, según Abreu et al. (2011), dada por la ecuación 3.

$$T_{gn} = 1,0335 \cdot T_{bs} + 0,456 \quad (03)$$

### 2.4. Elaboración de las redes neuronales artificiales

Los valores de la carga térmica de radiación (CTR) para cada día del año, en el calendario juliano, se introdujeron y procesaron por medio de la función “neuralnet”, disponible en el programa estadístico R (R CORE TEAM, 2019). Esa función permitió definir las posibles arquitecturas de redes neuronales artificiales. Luego, tomando como referencia los estudios de Pandorfi et al. (2011); Binoti et al. (2014a); Binoti et al. (2014b); Ferraz et al. (2014); Valente et al. (2014), se optó por la tipología con la estructura perceptron de múltiples capas (MPL), para el pronóstico del índice térmico, en función del día juliano.

En la secuencia, fueron definidas diversas arquitecturas de redes neuronales artificiales, teniendo como variables independiente y dependiente, respectivamente, en las capas de entrada y de salida, el día juliano y la carga térmica radiante. También, se probaron una y dos capas intermediarias, conteniendo hasta 15 neuronas cada una. Las variables de entrada y salida fueron normalizadas entre 0 y 1 para evitar la saturación y consecuentemente errores en los valores estimados. Después, los resultados fueron desnormalizados para poder expresarlos en la escala original, de acuerdo con las relaciones descritas en las ecuaciones 4 y 5.

$$V_{nor} = \frac{V_{ori} - V_{min}}{V_{max} - V_{min}} \quad (04)$$

$$V_{dnor} = V_{nor} \cdot (V_{max} - V_{min}) + V_{min} \quad (05)$$

en que: V<sub>nor</sub> = valor normalizado de CTR, adimensional; V<sub>ori</sub> = valor original de CTR, en W/m<sup>2</sup>; V<sub>min</sub> = valor mínimo de CTR, en W/m<sup>2</sup>; V<sub>max</sub> = valor máximo de CTR, en W/m<sup>2</sup>; V<sub>dnor</sub> = valor estimado desnormalizado de CTR, en W/m<sup>2</sup>.

Conforme Binoti et al. (2014a); Binoti et al. (2014b); Georgens et al. (2014); Valente et al. (2014), para reducir el número de redes neuronales obtenidas y seleccionar las más adecuadas, se calcularon el coeficiente de determinación (R<sup>2</sup>), el error absoluto medio (MAE), el error cuadrático medio (MSE), la raíz del error cuadrático medio (RMSE) y el

porcentaje medio del error absoluto (MAPE). Las redes de mejores índices se sometieron al análisis de normalidad para los residuos por medio de las pruebas de Kolmogorov-Smirnov, Lilliefors y Shapiro-Wilk. También, para esas redes se verificó el ajuste entre los valores observados y los estimados, aplicándose la prueba de t-Student.

Teniendo como referencia los trabajos de Binoti et al. (2014a); Binoti et al. (2014b); Ferraz et al (2014); Georgens et al. (2014); Soares et al. (2014); Valente et al. (2014), fueron calculados el coeficiente de correlación (r), el índice de concordancia de Willmott (Iw), bien como el índice de desempeño (Id), resultante del producto de los anteriores y que mide la proximidad entre valores estimados y observados. Inclusive, considerándose las investigaciones realizadas por Dai et al. (2014); Rodrigues et al. (2015); Sousa et al. (2015); Brighenti et al. (2016); Chaves et al. (2016); Lopes et al. (2016); Machado et al. (2017), en este estudio se verificó la eficiencia de las redes por medio del coeficiente de Nash-Sutcliffe (CNS), propuesto por Nash & Sutcliffe (1970).

Aunque los criterios analíticos citados anteriormente posibilitan concluir sobre la precisión de las redes para estimar la carga térmica de radiación (CTR), Battisti; Smolski (2019) sugieren evaluar el comportamiento de los residuos gráficamente con el propósito de verificar la presencia de tendencias inadecuadas en la distribución. En ese sentido, se elaboraron el histograma de los residuos, el diagrama del cuantil-cuantil con las bandas del intervalo de confianza, los gráficos con los residuos para las variables dependiente e independiente y el diagrama de dispersión para cada red seleccionada, en función del día juliano.

### 3. RESULTADOS

En el presente estudio se probaron 78 arquitecturas de redes neuronales artificiales, con una camada de entrada, una o dos intermediarias (ocultas) y una salida. El aumento de una camada intermediaria para dos elevó la precisión de los resultados. Sin embargo, el aumento de neuronas dentro de esas camadas no interfirió en el desempeño de la red. En la Tabla 1 se muestran los resultados correspondientes a las diez redes neuronales artificiales con índices satisfactorios. Segundo esa Tabla las arquitecturas 2, 5, 6 y 10 presentaron los mayores coeficientes de determinación (R<sup>2</sup>) y los menores valores del error absoluto medio (MAE), de la raíz del error cuadrático medio (RMSE) y del porcentaje del error absoluto medio (MAPE).

Las pruebas de Kolmogorov-Smirnov, Shapiro-Wilk y Lilliefors aplicadas para los residuos de las cuatro mejores redes neuronales artificiales evidenciaron probabilidades

superiores a 0,05 (Tabla 2). Según ese resultado se puede aceptar la normalidad de su distribución. También, en la Tabla 2, se observa que no hubo diferencias significativas entre los valores observados y los estimados por las cuatro redes, conforme la prueba de t-Student, comprobado por la probabilidad mayor que 0,99. Esos resultados constituyen la premisa básica para un adecuado ajuste entre los valores calculados a partir de los datos del INMET y los obtenidos por medio de las redes neuronales artificiales.

Tabla 1. Valores de los índices evaluados para cada arquitectura de red neuronal artificial.

Table 1. Values of the indexes evaluated for each artificial neural network architecture.

RNA	Arquitectura	R <sup>2</sup>	MAE	RMSE	MAPE
1	1:1-2-6-1:1	0,7597	0,0129	0,0170	1,2909
2	1:1-3-6-1:1	0,7755	0,0127	0,0166	1,2711
3	1:1-4-4-1:1	0,7635	0,0130	0,0170	1,2982
4	1:1-5-4-1:1	0,7658	0,0128	0,019	1,2846
5	1:1-6-5-1:1	0,7823	0,0123	0,0164	1,2325
6	1:1-6-6-1:1	0,7755	0,0127	0,0166	1,2353
7	1:1-7-8-1:1	0,7643	0,0127	0,0170	1,2735
8	1:1-8-5-1:1	0,7618	0,0130	0,0171	1,3013
9	1:1-8-7-1:1	0,7664	0,0128	0,0169	1,2784
10	1:1-9-5-1:1	0,7717	0,0127	0,0168	1,2740

La Tabla 3 contiene un resumen con los coeficientes e índices de desempeño y eficiencia. En esa Tabla se puede constatar un idóneo desempeño y una excelente eficiencia, evidenciada por el elevado coeficiente de Nash Sutcliffe. Esos valores fueron semejantes en las cuatro redes neuronales artificiales, indicando que todas son apropiadas para prever la Carga Térmica de Radiación y que pueden suministrar resultados análogos con adecuada precisión. Sin embargo, los resultados relativos a la arquitectura de red neuronal artificial cinco (1:1-6-5-1:1) se mostraron superiores al comparar sus índices de desempeño con las tres restantes tipologías (Tabla 3).

Los resultados de las pruebas analíticas confirmaron la normalidad de los residuos para las cuatro redes neuronales artificiales seleccionadas, bien como su adecuado ajuste, desempeño y eficiencia. No obstante, el análisis gráfico es una posibilidad conveniente para visualizar la distribución de los residuos referente a las suposiciones de normalidad e independencia, como también a la ocurrencia de valores estimados muy discrepantes (“outliers”) de los observados y su magnitud. En ese sentido, se elaboró el histograma de la densidad de probabilidad correspondiente a los residuos estandarizados (Figura 1).

Tabla 2. Valores de los índices evaluados para cada arquitectura de red neuronal artificial.

Table 2. Values of the indexes evaluated for each artificial neural network architecture.

RNA	Arquitectura	Resultados	Pruebas de normalidad			Prueba de ajuste
			Kolmogorov-Smirnov	Shapiro-Wilk	Lilliefors	t-Student
2)	1:1-3-6-1:1	Estadística	0,0513	0,9843	0,0513	0,0115
		Probabilidad	0,2923 (ns)	0,0523 (ns)	0,0795 (ns)	0,9908 (ns)
5)	1:1-6-5-1:1	Estadística	0,0617	0,9857	0,0617	0,0077
		Probabilidad	0,1241 (ns)	0,0583 (ns)	0,0571 (ns)	0,9939 (ns)
6)	1:1-6-6-1:1	Estadística	0,0518	0,9861	0,0518	0,0043
		Probabilidad	0,2824 (ns)	0,0867 (ns)	0,0752 (ns)	0,9965 (ns)
10)	1:1-9-5-1:1	Estadística	0,0535	0,9853	0,0535	0,0054
		Probabilidad	0,2465 (ns)	0,0829 (ns)	0,0817 (ns)	0,9957 (ns)

Tabla 3. Resumen con los resultados sobre el desempeño y la eficiencia de las redes neuronales artificiales.  
Table 3. Summary with the results for the performance and efficiency of the artificial neural networks.

RNA	Arquitectura	Indicativos de desempeño			Eficiencia
		Coefficiente de correlación	Concordancia de Willmott	Índice de desempeño	Coefficiente de Nash Sutcliffe
2)	1:1-3-6-1:1	0,9038	0,7943	0,7179	0,9988
5)	1:1-6-5-1:1	0,9071	0,8006	0,7262	0,9988
6)	1:1-6-6-1:1	0,9041	0,7953	0,7190	0,9988
10)	1:1-9-5-1:1	0,9023	0,7939	0,7163	0,9988

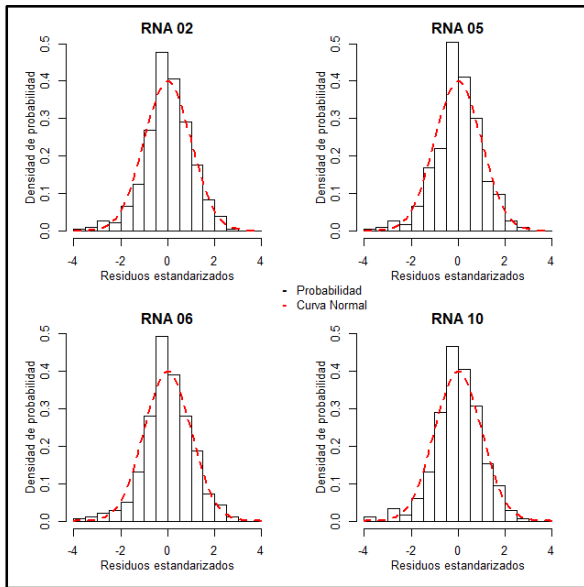


Figura 1. Histograma de la densidad de probabilidad de los residuos estandarizados para las redes neuronales artificiales.  
Figure 1. Histogram of the probability density of the standardized residuals for the artificial neural networks.

Como complemento del análisis de normalidad fue elaborado el gráfico de probabilidad normal de los residuos estandarizados con las bandas del intervalo de confianza para 95% (Figura 2). En esa Figura se puede observar que la mayor parte de los puntos coordinados formados por los valores de los cuantiles teóricos y de los residuos están muy próximos a la línea de referencia o bisectriz y solo algunos en los extremos se alejaron. Aún, se puede constatar que todos los puntos se mantuvieron entre los límites de confianza para 95%.

La validez de la suposición de independencia puede ser cualificada con base en el gráfico de dispersión de residuos, según el orden de colecta de los datos reales observados. Para esa finalidad se implementaron los diagramas de las Figuras 3 y 4 con los residuos estandarizados, en función de valores estimados de la Carga Térmica Radiante (CTR) y del día Juliano. En esas Figuras se incluyeron dos líneas horizontales con las ordenadas -2 y 2 para identificar, de forma fácil, el número de puntos con grandes desvíos.

Después de confirmar el adecuado ajuste de las cuatro redes neuronales artificiales seleccionadas por medio de los análisis analítico y gráfico, fue elaborado el diagrama de dispersión para representar los valores de la carga térmica de radiación observados y estimados, en función del día Juliano (Figura 5). En esa Figura se verifica que, los valores estimados por las cuatro redes acompañaron la tendencia presentada por los valores reales observados para la carga térmica de

radiación y no evidenciaron diferencias marcantes a lo largo del año, estando las cuatro curvas muy próximas.

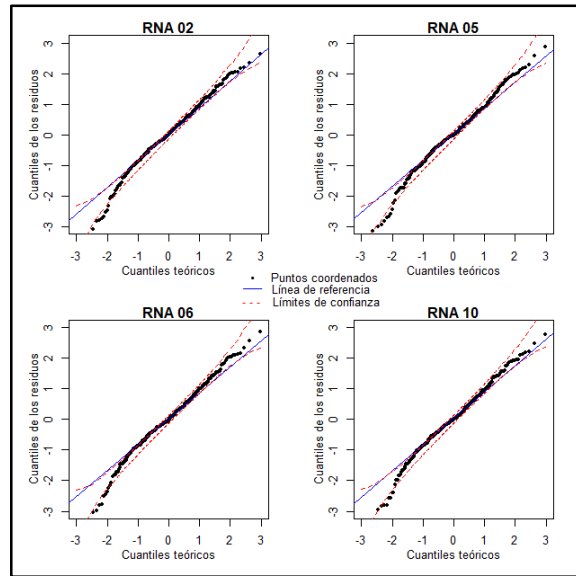


Figura 2. Gráfico de probabilidad normal de los residuos estandarizados con las bandas del intervalo de confianza para 95%.  
Figure 2. Normal probability plot of the standardized residuals with the confidence interval bands for 95%.

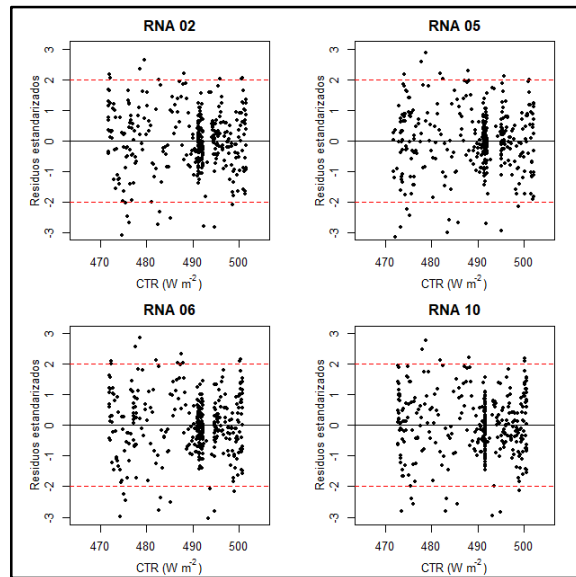


Figura 3. Dispersión de los residuos estandarizados, en función de los valores estimados de carga térmica de radiación.  
Figure 3. Dispersion of the standardized residuals, as a function of the estimated values of thermal radiation load.

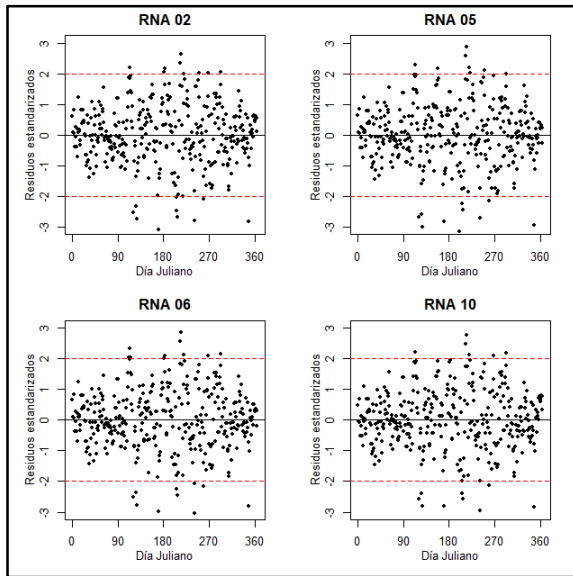


Figura 4. Dispersión de los residuos estandarizados, en función del día Juliano.

Figure 4. Dispersion of the standardized residuals, as a function of Julian day.

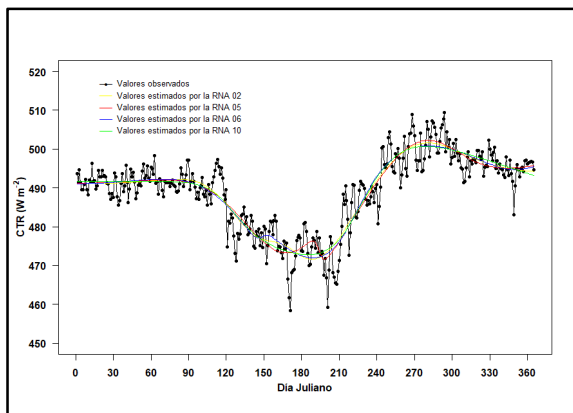


Figura 5. Dispersión de los valores de la carga térmica radiante, en función del día Juliano y curvas de los valores estimados por las cuatro redes neuronales artificiales seleccionadas.

Figure 5. Dispersion of the values of the radiant thermal load, as a function of Julian day and curves for the values estimated by the four selected artificial neural networks.

#### 4. DISCUSIÓN

Los valores del coeficiente de determinación obtenidos en este estudio fueron inferiores a los estimados por Binoti et al. (2014a); Binoti et al. (2014b); Georgens et al. (2014), siendo mayores que 0,9. Probablemente, esas discrepancias se deben a las elevadas oscilaciones diarias de las variables climáticas temperatura y velocidad del aire a lo largo de los años, lo que sin dudas puede generar diferencias entre los valores observados y los estimados mediante las redes neuronales. Sin embargo, los coeficientes de determinación de las diez arquitecturas fueron superiores a 0,7, mínimo valor considerado en este trabajo para iniciar la clasificación de las cuatro mejores con adecuado ajuste.

Los valores del coeficiente de correlación de Pearson para las cuatro redes seleccionadas fueron inferiores a los obtenidos por Binoti et al. (2014a); Binoti et al. (2014b);

Georgens et al. (2014). Esas diferencias pueden ser oriundas de la acentuada fluctuación de condiciones climáticas en la región, bajo la influencia de las variables humedad relativa, temperatura y velocidad del aire utilizadas en este trabajo. Por otro lado, los valores del coeficiente de eficiencia de Nash Sutcliffe (CNS) fueron superiores a los estimados por Sousa et al. (2015); Brighenti et al. (2016); Chaves et al. (2016); Lopes et al. (2016); Machado et al. (2017). Esas discrepancias pueden estar asociadas al elevado número de observaciones utilizadas en la presente investigación, lo que resultó en una mayor eficiencia de las redes desarrolladas. Además, las arquitecturas definidas en este estudio pueden haber contribuido para una adecuada aproximación de los valores estimados mediante las redes a los observados, aumentando su capacidad de predicción.

Los resultados evidenciaron la excelente capacidad de las redes neuronales para estimar o predecir valores con adecuada precisión, a pesar de la elevada variabilidad de la temperatura ambiente y velocidad del viento en la región. Se confirmó que, las redes detectaron satisfactoriamente la estacionalidad climática local, dada por la carga térmica de radiación, aspecto relevante para el manejo de animales en confinamiento. En esta investigación se corroboraron las afirmaciones formuladas por Binoti et al. (2014a); Binoti et al. (2014b); Ferraz et al. (2014); Georgens et al. (2014); Valente et al. (2014). Esos autores no recomiendan adoptar fórmulas para definir la arquitectura y el número de neuronas dentro de las capas ocultas, sino un análisis riguroso con diversas tipologías.

De acuerdo con la Figura 5, se deduce que los valores mínimos de la carga térmica radiante se mantuvieron muy próximos de  $475 \text{ W/m}^2$  y se obtuvieron durante el mes de julio, correspondiendo a los días 180 y 190 del calendario Juliano. Esos valores fueron inferiores a los determinados, en período semejante, por Avila et al. (2013), en torno de  $550 \text{ W/m}^2$ . Sin embargo, los valores de este estudio fueron superiores a  $117,73 \text{ W/m}^2$ , estimados por Brettas et al. (2017). Esas diferencias se deben, probablemente, a las características climáticas de cada región, lo que evidencia la importancia de predecir la carga térmica radiante con adecuada precisión, para el eficiente manejo de animales en términos de confort ambiental.

#### 5. CONCLUSIONES

Las redes neuronales elaboradas presentaron adecuada confiabilidad y eficiencia en las predicciones, justificando su aplicación para auxiliar la tomada de decisión en el planeamiento, gestión y manejo de animales. Las redes del tipo perceptron formadas por tipologías de dos capas ocultas evidenciaron superioridad para estimar la carga térmica radiante, en función de día Juliano, posibilitando identificar los días del año más y menos favorables al stress animal, de forma precisa.

#### 6. REFERENCIAS

- ABREU, P. G.; ABREU, V. M. N.; FRANCISCON, L.; COLDEBELLA, A.; AMARAL, A. G. Estimativa da temperatura de globo negro a partir da temperatura de bulbo seco. **Engenharia na Agricultura**, Viçosa, v. 19, n. 6, p. 557-563. 2011.
- AVILA, A. S.; JÁCOME, I. M. T. D.; FACCENDA, A.; PANAZZOLO, D. M.; MÜLLER, E. R. Avaliação e correlação de parâmetros fisiológicos e índices

- bioclimáticos de vacas holandês em diferentes estações. **Revista REGET**, Santa Maria, v. 14, n. 14, p. 2878-2884, 2013. DOI: <http://dx.doi.org/10.5902/2236117010747>
- BATTISTI, I. D. E.; SMOLSKI, F. M. S. **Software R: Análise estatística de dados utilizando um programa livre**. 1ª Edição. Editora FAITH, Bagé. 2019. 173p.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L. Redes neurais artificiais para estimação do volume de árvores. **Revista Árvore**, Viçosa, v. 38, n. 2, p. 283-288, 2014a.
- BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; SILVA, A. A. L.; PONTES, C. Utilização de redes neurais artificiais para a projeção da distribuição diamétrica de povoamento equiâneos. **Revista Árvore**, Viçosa, v. 38, n. 4, p. 747-754. 2014b.
- BRETTAS, P. K. M.; NASCIMENTO, M. R. B. M.; GUIMARÃES, E. C.; SOUZA, G. P. Melhor índice de estresse térmico para novilhas leiteiras mestiças. **Acta Scientiae Veterinariae**, Porto Alegre, v. 45, n. 1486, p. 1-8, 2017.
- BRIGHENTI, T. M.; BONUMÁ, N. B.; CHAFFE, P. L. B. Calibração hierárquica do modelo SWAT em uma bacia hidrográfica Catarinense. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 21, n. 1, p. 53-64, 2016. DOI: <http://dx.doi.org/10.21168/rbrh.v21n1.p53-64>
- CHAVES, H. M. L.; JANKOSZ, A. V.; LUCCHESI, L. A.; MARQUES, P. Acurácia do modelo hydrus na predição da lixiviação de nitrato resultante da aplicação de lodo de esgoto tratado a solos de diferentes texturas. **Revista Brasileira de Recursos Hídricos**, Porto Alegre, v. 21, n. 1, p. 99-104. 2016. DOI: <http://dx.doi.org/10.21168/rbrh.v21n1.p99-104>
- COUTINHO, G. S.; MAGALHÃES, P. C. M.; FORMIGONI, A. S.; VALLE, G. R.; MOREIRA, A. H. Conforto térmico e manejo de suínos na maternidade levando em consideração o bem-estar animal. **Revista Eletrônica Nutritime**, Viçosa, v. 11, n. 1, p. 3109-3119, 2014.
- DAI, Z.; BIRDSEY, R. A.; JOHNSON, K. D.; DUPUY, J. M.; HERANDEZ-STEFANONI, J. L. Modeling carbon stocks in a secondary tropical dry forest in the Yucatan Peninsula, Mexico. **Revista Water, Air & Soil Pollution**, Switzerland, v. 225, n. 4, p. 1925, 2014. DOI: <https://doi.org/10.1007/s11270-014-1925-x>
- ESMAY, M. L. **Principles of animal environment**. 2 ed. West Port: AVI, 1982. 325p.
- FERRAZ, P. F. P.; YANAGI JUNIOR, T.; JULIO, Y. F. H.; CASTRO, J. O.; GATES, R. S.; REIS, G. M.; CAMPOS, A. T. Predicting chick body mass by artificial intelligence-based models. **Pesquisa Agropecuária Brasileira**, Brasília, v. 49, n. 7, p. 559-568, jul. 2014. DOI: <https://doi.org/10.1590/S0100-204X2014000700009>
- GEORGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B.; CEOLIN, A. Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais. **Revista Árvore**, Viçosa, v. 38, n. 2, p. 289-295. 2014.
- INSTITUTO NACIONAL DE METEOROLOGIA (INMET). **Banco de dados meteorológicos para ensino e pesquisa**. Disponível em: <<http://www.inmet.gov.br/>>
- portal/index.php?r=bdmep/bdmep>. Acesso em: 10 janeiro 2020.
- LOPES, F. B.; NOVO, E. M. L. M.; BARBOSA, C. C. F.; ANDRADE, E. M.; FERREIRA, R. D. Simulação de bandas espectrais do sensor MERIS para estimativas das concentrações de clorofila-a em reservatório da região semiárida. **Revista Agro@ambiente On-line**, Boa Vista, v. 10, n. 2, p. 96-106, 2016. DOI: <http://dx.doi.org/10.18227/1982-8470ragro.v10i2.3482>
- MACHADO, A. R.; MELLO JUNIOR, A. V.; WENDLAND, E. C. Avaliação do modelo J2000/JAMS para modelagem hidrológica em bacias hidrográficas brasileiras. **Revista Engenharia Sanitária Ambiental**, Rio de Janeiro, v. 22, n. 2, p. 327-340, 2017. DOI: <http://dx.doi.org/10.1590/S1413-41522016145177>
- NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models. Part I: A discussion of principles. **Journal of Hydrology**, Amsterdam, v. 10, n. 3, p. 282-290, 1970. DOI: [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- NAVAS, T. O.; OLIVEIRA, H. F.; CARVALHO, F. B.; STRINGHINI, J. H.; CAFÉ, M. B.; HELLMMEISTER FILHO, P. Estresse por calor na produção de frangos de corte. **Revista Eletrônica Nutritime**, Viçosa, v. 13, n. 1, p. 4550-4557, 2016.
- TO, O. V.; BITTAR, D. Y. Análise do conforto térmico e sua influência na produção e qualidade do leite em ambiente de domínio de cerrado. **Revista PUBVET**, Maringá, v. 12, n. 4, p. 1-6, 2018. DOI: <https://doi.org/10.22256/pubvet.v12n4a75.1-6>
- PANDORFI, H.; SILVA, I. J. O.; SARNIGHAUSEN, V. C. R.; VIEIRA, F. M. C.; NASCIMENTO, S. T.; GUISELINI, C. Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura. **Revista Brasileira de Zootecnia**, Viçosa, v. 40, n. 3, p. 676-681, 2011. DOI: <https://doi.org/10.1590/S1516-35982011000300028>
- PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Updated world of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, Göttingen, v. 11, n. 5, p. 1633-1644, 2007. DOI: <https://doi.org/10.5194/hess-11-1633-2007>
- R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Viena, Austria. Disponível em: <<http://www.R-project.org/>>. Acesso em: 12 janeiro 2019.
- RODRIGUES, E. L.; ELMIRO, M. A. T.; JACOBI, C. M.; LAMOUNIER, W. L. Aplicação do Modelo SWAT na avaliação do consumo de água em áreas de florestas plantadas na bacia do rio Pará, Alto São Francisco, em Minas Gerais. **Revista Sociedade & Natureza**, Uberlândia, v. 27, n. 3, p. 485-500, 2015. DOI: <http://dx.doi.org/10.1590/1982-451320150309>
- SANTOS, D. S.; ARCE, A. I. C.; PIZA, L. V.; SILVA, A. C. S.; COSTA, E. J. X.; TECH, A. R. B. Redes bluetooth associadas a redes neurais artificiais para monitoramento de suínos. **Revista Archivos de Zootecnia**, Córdoba, v. 65, n. 252, p. 557-563, 2016.
- SOARES, F. C.; ROBAINA, A. D.; PEITER, M. X.; RUSSI, J. L.; VIVAN, G. A. Redes neurais artificiais na estimativa da retenção de água do solo. **Revista Ciência Rural**, Santa Maria, v. 44, n. 2, p. 293-300, 2014.

- SOUSA, A. M. L.; VITORINO, M. I.; CASTRO, N. M. R.; BOTELHO, M. N.; SOUZA, P. J. O. P. Evapotranspiration from remote sensing to improve the SWAT model in Eastern Amazonia. **Floresta e Ambiente**, Seropédica, v. 22, n. 4, p. 456-464, 2015. DOI: <https://doi.org/10.1590/2179-8087.083814>
- VALENTE, G. F. S.; GUIMARÃES, D. C.; GASPARDI, A. L. A.; OLIVEIRA, L. A. Aplicação de redes neurais artificiais como teste de detecção de fraude de leite por adição de soro de queijo. **Revista do Instituto de Laticínios Cândido Tostes**, Juiz de Fora, v. 69, n. 6, p. 425-432, 2014. DOI: <https://doi.org/10.14295/2238-6416.v69i6.353>