



## ESTIMAÇÃO DO ÍNDICE DE BULBO ÚMIDO TERMÔMETRO DE GLOBO (IBUTG) PARA AMBIENTES A CÉU ABERTO POR MEIO DE REDES NEURAIS ARTIFICIAIS UTILIZANDO DADOS DE ESTAÇÕES METEOROLÓGICAS

*The Wet-Bulb Globe Temperature (WBGT) index prediction for open-air environments through Artificial Neural Networks using weather station data*

*Estimación de la temperatura del Globo de Bulbo Húmedo (WBGT) para ambientes de cielo abierto a través de Redes Neurales Artificiales utilizando datos de estaciones meteorológicas*

Ivan Julio Apolonio Callejas  

Departamento de Arquitetura e Urbanismo/Faculdade de Arquitetura, Engenharia e Tecnologia,  
Universidade Federal de Mato Grosso - UFMT  
ivancalejas1973@gmail.com

Ermete Cauduro Bianchi  

Departamento de Ensino – Campus Pontes e Lacerda, Instituto Federal de Mato Grosso (IFMT)  
ermete.bianchi@ifmt.edu.br

**Resumo:** Este trabalho objetiva demonstrar a viabilidade técnica de estimação do Índice de Bulbo Úmido Termômetro de Globo (IBUTG) para ambiente a céu aberto sem fonte artificial de calor por meio de dados medidos em estações meteorológicas convencionais, a partir da utilização de Redes Neurais Artificiais (RNA). Para tanto, procedeu-se a instalação de termômetros de bulbo úmido natural e de globo em uma estação meteorológica convencional, com a finalidade de calcular o IBUTG sincronamente com as variáveis de temperatura, umidade e velocidade do ar, bem como radiação solar global e pressão atmosférica. O treinamento da RNA foi conduzido com a utilização de 81 dias de medições. Algumas configurações da RNA foram modificadas com o intuito de encontrar a de melhor desempenho para a rede. Para o teste de validação do treinamento, selecionou-se dia de céu aberto, nublado e com precipitação, com condições sinópticas que impõem elevado estresse ao calor. O IBUTG estimado pelo RNA acompanhou o ciclo diário do IBUTG medido, com a melhor configuração de rede (três camadas e cinco neurônios) estimando erro médio quadrático diário de 0,2724°C e erro médio absoluto de 0,1818°C (com erro percentual de apenas

0,7%). Comprova-se a viabilidade técnica de estimar o IBUTG com adequada precisão a partir de dados meteorológicos, o que permite que a técnica de RNA possa ser utilizada como estratégia de orientação do gerenciamento do risco ocupacional.

**Palavras-chave:** Meteorologia instrumental. Inteligência artificial. Gerenciamento de risco. Estresse ao calor.

**Abstract:** This work aims to demonstrate the technical feasibility of estimating the wet-bulb globe temperature (WBGT) for the open-air environment without artificial heat source through data measured in conventional meteorological stations using Artificial Neural Networks (ANN). To this end, it was installed a natural wet bulb and globe thermometers in a conventional meteorological station to calculate the IBUTG synchronously with the variables of temperature, humidity, and airspeed, as well as direct solar radiation and atmospheric pressure. The ANN training was conducted using 81 days of measurements. Some RNA configurations have been modified to find the one with the best performance for the network. For the training validation test, a day with open sky, cloudy and rainy conditions were selected, with synoptic conditions that impose high heat stress. The WBGT estimated by the ANN followed the daily cycle of the measured IBUTG, with the best network configuration (three layers and five neurons) estimating an average daily square error of 0.3060°C and an absolute mean error of 0.1818°C (a 0.7% of percentage error). We concluded for the technical feasibility of estimating WBGT with adequate precision from meteorological data is proven, which allows the ANN technique to be used as an occupational risk management strategy.

**Keywords:** Instrumental meteorology. Artificial intelligence. Risk management. Heat stress.

**Resumen:** Este trabajo tiene como objetivo demostrar la viabilidad técnica de estimar el Índice de Bulbo Húmedo del Termómetro de Globo (WBGT, en inglés) para ambiente cielo abierto a través de datos medidos en estaciones meteorológicas convencionales, utilizando Redes Neuronales Artificiales (ANN). Para ello, la instalación de termómetros de bulbo húmedo natural y de globo en una estación meteorológica convencional, con la finalidad de calcular el (WBGT) de forma sincrónica con las variables de temperatura, humedad y velocidad del aire, así como la radiación solar global y presión atmosférica. El entrenamiento de ANN se llevó a cabo utilizando 81 días de mediciones. Algunas configuraciones de ARN se han modificado para encontrar la que tiene el mejor rendimiento para la red. Para la prueba de validación del entrenamiento se seleccionó un día abierto, nublado y lluvioso, con condiciones sinópticas que imponen un alto estrés térmico. El WBGT estimado por el RNA siguió el ciclo diario del WBGT medido, con la mejor configuración de red (tres capas y cinco neuronas) estimando error cuadrático diario promedio de 0.2724°C y error promedio absoluto de 0.1818°C (con un porcentaje de error de solo 0.7%). Se comprueba la viabilidad técnica de estimar el IBUTG con adecuada precisión a partir de datos meteorológicos, lo que permite utilizar la técnica de la RNA como estrategia orientadora para la gestión de riesgos laborales.

**Palabras clave:** Meteorología instrumental. Inteligencia artificial. Gestión de riesgos. Estrés por calor.

Submetido em: 07/05/2021

Aceito para publicação em: 17/03/2022

Publicado em: 10/04/2022

## 1. INTRODUÇÃO

A sobrecarga térmica ou o estresse ao calor é um processo desencadeado pela combinação das contribuições da atividade metabólica, pelas vestimentas exigidas para o trabalho e, principalmente, pelos fatores ambientais, decorrentes das condições do tempo atmosférico. Assim, os elementos do clima de uma região como a temperatura e umidade do ar, velocidade do vento, radiação solar e precipitação são determinantes para a resposta fisiológica ao estresse térmico por calor (BORGES, CALLEJAS, DURANTE, 2020).

Em regiões de climas tropicais, as atividades laborais desenvolvidas por agricultores, garis, carteiros, operários da construção civil, dentre outros, em condição de céu aberto em virtude de condições ambientais desfavoráveis, podem elevar a temperatura interna do corpo humano, induzindo a ativação do sistema termorregulador visando evitar a elevação da temperatura central do corpo por meio de processos como a vasodilatação e ativação das glândulas sudoríparas.

Em razão disso, distúrbios fisiológicos decorrentes da sobrecarga térmica como desidratação, cãibras e exaustão por calor entre outras doenças ocupacionais são muito frequentes. Em casos mais graves, quando o sistema termorregulador é afetado pela sobrecarga térmica, como no caso da intermação, os danos causados aos trabalhadores podem ser severos, podendo colocar a vida dos mesmos em risco (AMORIM et al., 2019).

Com a finalidade de garantir que o trabalho seja executado de forma segura e salubre, as Normas Regulamentadoras NR.º 15 e NR.º 09 (MINISTÉRIO DO TRABALHO E EMPREGO, 1978a, 1978b) estabelecem que o Índice de Bulbo Úmido Termômetro de Globo (IBUTG) seja utilizado para avaliar a exposição ocupacional ao calor em ambientes fechados (sem carga solar) ou externos com e sem fonte artificial de calor (sujeitos a carga solar).

No caso de ambientes sem fontes artificiais, a NR.º 09 indica a necessidade da realização da medição do referido índice nos locais de trabalho, por meio de equipamentos específicos para determinação das temperaturas de bulbo seco (Tbs), de bulbo úmido natural (Tbn) e de globo (Tg). Entretanto, a avaliação em ambientes a céu aberto por parte das empresas não é um recurso de engenharia usualmente utilizado, uma vez que tais instrumentos não são de uso corrente, além de muitas vezes serem tecnicamente inviáveis, uma vez que determinadas atividades como as de garis e carteiros são executadas em locais não fixos, dificultando sua avaliação (CALLEJAS, 2012).

Uma estratégia para se mensurar as condições físicas do ambiente laboral é por meio da utilização de estações meteorológicas, uma vez que elas fornecem informações do tempo atmosférico, como pressão atmosférica, temperatura e umidade relativa do ar, precipitação, radiação solar, direção e velocidade do vento, entre outros. No entanto, apesar de subsidiarem uma análise preliminar do risco ocupacional a partir da temperatura (bulbo seco) e umidade do ar, estes parâmetros não são suficientes para fornecer uma medida mais completa das condições ambientais em termos de nível de estresse térmico aos quais os trabalhadores estão expostos, uma vez que não consideram nem o efeito da radiação solar e nem o efeito do vento (BUDD, 2008).

Apesar disso, as variáveis de temperatura de bulbo úmido natural e temperatura de globo, não convencionalmente medidas nas estações meteorológicas, guardam estreita relação com as variáveis meteorológicas, porém não se relacionando de forma linear com as mesmas, o que dificulta a estimativa das mesmas. Isso se dá pelo fato do termômetro de bulbo úmido natural responder à evaporação que ocorre no ambiente, sendo influenciado tanto pelas condições de umidade quanto pela presença de ventilação, enquanto que a temperatura de globo representa o efeito combinado do calor radiante/ radiação solar, da velocidade e temperatura do ar do ambiente onde esse termômetro esteja inserido (CALLEJAS, 2012).

Apesar da dificuldade, estudos têm apontado à possibilidade de derivar o IBUTG a partir de dados disponíveis nas estações meteorológicas (MAIA, RUAS e BITENCOURT, 2015; ROSCANI et al., 2017). Com esta finalidade, são utilizados cálculos psicrométricos para estimativa da  $T_{bn}$  e algoritmos para a derivação da  $T_g$ , a qual é obtida por meio da condição de equilíbrio do globo com o ambiente, com este parâmetro sendo fortemente influenciado pelas condições de céu, ou seja, pela maior ou menor intensidade da radiação direta e difusa. Trata-se de um processo que envolve cálculos matemáticos e simplificações para que possa derivar o referido índice.

Outra alternativa pode ser conduzida por meio da utilização de técnicas de estimativa, visando derivar um modelo matemático que represente o fenômeno pesquisado. Um modelo matemático de um sistema real é um análogo matemático que representa algumas das características observadas no sistema (AGUIRE, 2007). Nesse sentido, a identificação de um sistema tem como objetivo propor um modelo matemático que melhor

represente a relação entre dados amostrados do sinal de entrada e do sinal de saída. Existem várias técnicas que podem ser utilizadas para a estimação de um modelo, e, dependendo da sua complexidade, pode-se utilizar a de regressão polinomial, regressão linear múltipla, analítica e modelo de um diodo, entre outros (MELLIT et al., 2013).

Esta pesquisa foca no uso da técnica de Redes Neurais Artificiais (RNA), um tipo de inteligência artificial para solução de problemas complexos por meio de reconhecimento de padrões, classificação, sistemas de controle, aproximação de funções, bem como para aplicação como modelo de previsão (ANOCHI, 2015). São estruturas baseadas nos neurônios humanos, que, conforme vão sendo treinados pelo ambiente, vão aprendendo como as conexões funcionam, dando mais importância para algumas do que para outras (HAYKIN, 2001).

São capazes de aprender a reagir de acordo com cada situação. Nessa técnica existem as variáveis de entrada que representam o ambiente e as variáveis de saída, que são o comportamento e/ou reações conforme o ambiente. Os modelos de RNA têm sido aplicados para retratar a inter-relação não linear entre uma infinidade de fatores com vistas a prover respostas mais precisas ao comportamento e/ou reações características de um determinado ambiente (CHAN e CHAU, 2019).

Com esta finalidade, aponta-se a sua utilização para estimar a concentração de ozônio de superfície em função de dados diários de clima (SOUZA, PAVÃO e OLIVEIRA, 2014), previsão climática de precipitação atmosférica (ANOCHI, 2015), para estimativa de velocidade de vento com a finalidade de previsão de geração eólica (CAMELO, LUCIO e LEAL JUNIOR, 2017), para prever a avaliação da percepção térmica em parques urbanos a céu aberto (CHAN e CHAU, 2019), para fins de modelagem do comportamento de séries temporais climáticas (CARVALHO e DELGADO, 2020), para estimativa da temperatura do ar para fins de previsão de ilha de calor urbana (DE PAULA et al., 2021), entre outros. Todas estas pesquisas apontam a adequada viabilidade de utilização das RNAs para fins de estimação das variáveis de interesse.

Em se tratando do uso das RNAs para a estimação das condições de estresse térmico, a revisão da literatura revelou a utilização da técnica voltada para a área de conforto térmico, com a aplicação de modelos de RNA para a previsão do índice Voto Médio Preditado (*Predicted Mean Vote* – PMV, em inglês) (GAO e BAI, 2003; ATTHAJARIYAKUL e

LEEPHAKPREEDA, 2005; FERREIRA et al., 2012; PALLADINO, NARDI e BURATTI, 2020) e para o índice de Temperatura Fisiológica Equivalente (PET) (MOUSTRIS, NASTOS e PALIATSOS, 2013; MOUSTRIS et al., 2018). Porém, na área de exposição ocupacional ao calor, seu uso ainda é incipiente.

Kaiho, Takamatsu e Itoh (2019) estimaram a variável Tg usando RNAs com vistas a estimar o índice de bulbo úmido temperatura de globo (IBUTG). O número de camadas ocultas (2, 3 e 4) e seus respectivos neurônios (10, 20, 50, 100, 200) foram progressivamente alterados com intuito de identificar a melhor configuração da rede para as estimativas. A função de ativação entre as camadas usada foi a Unidade Linear Retificada. O melhor desempenho foi obtido com a configuração de três camadas e 20 nós, com coeficiente de determinação de 0,78 e desvio padrão de 1,71 °C para o Tg. Os valores de IBUTG medidos e estimados a partir dos valores Tg apresentaram erro máximo de 1,0°C entre si.

Mahgoub, Gowid e Ghani (2020) utilizaram a RNAs para reduzir o erro das estimativas do índice IBUTG derivadas a partir de imagens termográficas. As seguintes variáveis meteorológicas de entrada foram usadas: pressão atmosférica, temperatura do ar (estimada a partir da imagem térmica), umidade relativa do ar, velocidade do ar e temperatura de globo. A estrutura da rede utilizada foi a *Feedforward Backpropagation* com algoritmo de aprendizagem *Levenberg-Marquardt* (LM), sendo a Raiz do Erro Quadrático Médio, expresso em porcentagem, usada como indicador quantitativo para o desempenho da rede. O número de camadas foi aumentado iterativamente de 1 a 3 e o número de nós, variado de 2 a 50. Os resultados indicaram que a RNA com uma única camada e 35 nós foi a que apresentou melhor precisão para as estimativas. Com o uso da estratégia proposta, o erro médio máximo do IBUTG, derivado a partir das imagens termográficas, se reduziu de 6,65% para 1.38%.

Assim, diante da potencialidade de aplicação das RNAs para fim de avaliação das condições de estresse térmico, este trabalho objetiva demonstrar a viabilidade técnica de estimação do Índice de Bulbo Úmido Termômetro de Globo (IBUTG) para ambiente externo com e sem carga solar por meio de dados medidos em estações meteorológicas convencionais com a utilização de Redes Neurais Artificiais. Busca-se identificar alternativa para o gerenciamento do risco ocupacional do estresse térmico ao calor nas cidades.

## 2. MATERIAIS E MÉTODOS

### 2.1. Materiais

Para as medições das variáveis meteorológicas foram utilizados os seguintes sensores da Marca OnsetComp:

a) Termo-Higrômetro, Modelo S-THB para avaliação da temperatura e umidade do ar (temperatura – precisão de 0,2°C e resolução de 0,02°C entre 0°C a 50°C; umidade – precisão de  $\pm 2,5\%$  e resolução de 0,1% entre 10% a 90%);

b) Piranômetro, Modelo S-LIB, para a avaliação da radiação solar global incidente (Faixa de leitura – 0 - 1280 W/m<sup>2</sup>; precisão de  $\pm 10$  W/m<sup>2</sup> ou 5%; resolução de 1,25W/ m<sup>2</sup>);

c) anemômetros de conchas, Modelo S-WSA (velocidade) e S-WCA (velocidade e direção), para avaliação do perfil de velocidade do vento (faixa de medição: 0 a 45m/s; precisão de 1,1 m/s ou  $\pm 4\%$ ; resolução de 0,38 m/s);

d) temperatura de globo, confeccionado a partir de um termômetro de bulbo seco, modelo S-TMB M006, (faixa de operação de -40°C a 100°C), no qual o sensor foi inserido no interior de esfera plástica de cor preta com diâmetro de 6,3 cm; e,

e) temperatura de bulbo úmido, confeccionado a partir de um termômetro de bulbo seco, modelo S-TMB M006, (faixa de operação de -40°C a 100°C), no qual o sensor foi encoberto por uma malha porosa parcialmente mergulhada em um recipiente com água destilada para que o bulbo do termômetro permanecesse permanentemente umedecido.

A Figura 1a ilustra a estação meteorológica instalada no Campus da Universidade Federal de Mato Grosso - município de Cuiabá-MT (15°36'29,44"S, 56° 3'52,96"O, 177m), com os sensores utilizados para a determinação do índice IBUTG. Os dados produzidos pelos sinais e/ou pulsos elétricos dos sensores dos equipamentos meteorológicos foram processados e armazenados por Datalogger, Marca OnsetComp, Modelo U30-NRC-VIA, em intervalos de 10s, com médias a cada 5 minutos. Assim, tanto no procedimento de treinamento quanto nas estimativas pelo método das redes neurais foram conduzidas com as variáveis para essa taxa de amostragem. Todos os sensores atendem a recomendação da ISO 7726 (ISO, 1998) e foram calibrados em laboratório antes da realização do experimento com o equipamento confeccionado pela empresa Instruterm, modelo TGD 400, referencia para a medição da exposição ocupacional (Figura 1b).

**Figura 1** - (a) Sensores instalados para a derivação do IBUTG e (b) calibração.



(a)

(b)

**Fonte:** Elaborado pelos autores (2021).

## 2.2. Métodos

### 2.2.1. Cálculo do IBUTG

Conforme estabelecido na NR.º 15 (MINISTÉRIO DO TRABALHO E EMPREGO, 1978a), o Índice de Bulbo Úmido Termômetro de Globo - IBUTG é utilizado para avaliar a exposição ao calor em ambientes internos ou externos. Seu cálculo do IBUTG é definido pelas seguintes Equações 1 e 2 (GIAMPAOLI, 2018):

a) Para ambientes internos ou externos sem carga solar

$$(1) \quad IBUTG = 0,7.Tbn + 0,3.Tg$$

b) Para ambientes externos com carga solar

$$(2) \quad IBUTG = 0,7.Tbn + 0,1.Tbs + 0,2.Tg$$

em que Tbn é a temperatura de bulbo úmido natural; Tg a temperatura de globo; e, Tbs a temperatura de bulbo seco. Os dados coletados na estação foram trabalhados em planilha eletrônica para fins de derivação do índice IBUTG medido. Para o período diurno, com presença de radiação solar, utilizou-se o Equação 2 para a estimativa do IBUTG, e no noturno, a Equação 1.

### 2.2.2. Estimação por meio da aplicação da rede neural

A estimativa foi conduzida por meio do software MATLAB (MATHWORKS, 2020), utilizando a toolbox de redes neurais (nntool). Como as RNA precisam “aprender” o




ambiente para posteriormente gerar uma resposta/atitude ao mesmo, a sua idealização ocorre por meio da definição de sua arquitetura estrutural básica que é composta por três camadas: a de entrada, a oculta e de saída.

Os neurônios da camada de entrada recebem os parâmetros de entrada da rede os quais são conectados a nós da camada oculta. Os neurônios na camada oculta, após o processamento dos dados recebidos, se conectam a camada de saída, com intuito de gerar as variáveis de resposta (saída). Cada conexão entre os neurônios têm um peso ligado a eles, que são ajustados durante a fase de treinamento da RNA com o intuito de aperfeiçoar os valores da saída durante a fase de aprendizado supervisionado da rede, sempre gerando variáveis de saída para a rede para cada padrão de entrada idealizada pelo usuário (aprendizado supervisionado). Os pesos obtidos a partir do treinamento da RNA são então usados para calcular as variáveis de saídas (alvo) a partir de novos dados de variáveis de entrada.

Sinteticamente, a realização da estimacão é feita por meio de passos indicados na Figura 2. O primeiro consiste no treinamento da rede neural e o segundo na simulacão da rede neural, por meio da realizacão da estimacão.

**Figura 2** - Fluxograma das etapas de estimacão



**Fonte:** Elaborado pelos autores (2021).

As variáveis meteorológicas consideradas na estimacão no presente estudo foram seis: cinco variáveis de entrada relacionadas ao ambiente (pressão atmosférica, temperatura e umidade relativa do ar, velocidade do vento e radiação solar global) e uma relacionada à variável alvo, no caso o IBUTG medido (derivado a partir da Tbs, Tbu e Tg medidos simultaneamente com as variáveis meteorológicas). Essa etapa foi utilizada para o treinamento da rede neural.

Treinada a rede, passa-se para a fase de validacão, onde se utiliza novo grupo de dados de variáveis (distinto do treinamento – amostra independente) para que seja feita a estimacão da variável de saída (IBUTG estimado). Por fim, realiza-se o procedimento de analise de desempenho da estimacão, por meio da comparacão dos dados do IBUTG

medidos, visando validar o desempenho da RNA.

Para modelar a estrutura básica da rede neural dentro da *Toolbox* do software MATLAB, é necessário definir alguns parâmetros de sua configuração. Há uma série de estruturas que devem ser configuradas, relacionadas às funções de treinamento, de aprendizagem adaptativa e de desempenho. Neste estudo, as configurações adotadas para o treinamento da rede neural seguiram às recomendações apontadas por Bianchi (2018) e Mahgoub, Gowid e Ghani (2020), que estimaram a variável de interesse a partir de dados meteorológicos, obtendo excelente desempenho com tal configuração. Nesse sentido, utilizou-se para a rede a estrutura *Feedforward Backpropagation*, com algoritmo de aprendizagem *Levenberg-Marquardt*, denominado *TRAINLM* no MATLAB.

Uma rede neural multicamadas *Feedforward* possui uma ou mais camadas ocultas, nas quais se encontram os neurônios, que correlacionam à camada externa e a saída da rede. Em regra geral, ao se aumentar o número de camadas escondidas, a rede se torna mais hábil para entender a entrada. O termo escondido é utilizado porque esta parte da rede neural não é vista nem pela entrada e nem pela saída da rede (HAYKIN, 2001).

Já o algoritmo *Backpropagation* envia o sinal de erro da camada de saída para a camada de entrada, dessa forma os pesos são ajustados em função do erro propagado (ENGELBRECHT, 2007). Por fim, o algoritmo de aprendizagem *Levenberg-Marquardt* é uma variação do Método de *Newton*, que foi projetado para minimizar as funções que são somas de quadrados de outras funções não lineares (HAGAN et al., 2014). Tanto as camadas oculta e de saída utilizaram a função de transferência *Tansig*. A Tabela 1 apresenta a configuração utilizada na rede para fazer a estimação do IBUTG.

**Tabela 1** - Configurações da rede neural artificial utilizada.

<b>Estrutura</b>	<b>Backpropagation</b>
Algoritmo de aprendizagem	<i>Levenberg-Marquardt</i>
Número de variáveis de entrada (R)	Variável
Número de camadas ocultas (M)	Variável
Número de neurônios em cada camada oculta (N)	Variável
Função de ativação das camadas ocultas	<i>Tansig</i>
Função de ativação da camada de saída	<i>Tansig</i>
Número de variáveis na camada de saída (Output)	1


**Fonte:** Elaborado pelos autores (2021).

Com intuito de encontrar o modelo que melhor representasse a estimativa do IBUTG (camada de saída), inicialmente testou-se todas as variáveis medidas na estação meteorológica (pressão atmosférica, temperatura e umidade do ar, velocidade do vento e radiação solar direta). Posteriormente, excluiu-se a variável pressão atmosférica, uma vez que ela em pouco influenciou o índice pesquisado nas etapas preliminares de aprendizado supervisionado da rede.

Há várias possibilidades de configuração do número de camadas ocultas ( $S$ ) e número de neurônios em cada camada oculta ( $N$ ). Ao se tomar como referência os trabalhos de Bianchi (2018) e Mahgoub, Gowid e Ghani (2020), optou-se por variar o número de camadas ocultas de 1 a 4, uma vez que números maiores conduziram a redução no desempenho da estimativa da variável de saída (IBUTG), além de maior tempo de processamento para o treinamento da rede neural. O mesmo ocorreu para o número de neurônios em cada camada oculta, que foi variado de 5 em 5, até 10, com valores maiores não aperfeiçoando o desempenho da rede e aumentando o tempo de processamento.

A Figura 3 ilustra a representação da rede neural utilizada para o modelo em que se obteve o melhor desempenho de estimativa: a entrada com quatro variáveis (temperatura do ar, umidade do ar, velocidade do ar e radiação solar global) ( $R=4$ ), três camadas ocultas ( $M=3$ ), cada uma com cinco neurônios ( $S=5$ ) e uma camada de saída ( $Out=1$ , estimativa do IBUTG). Esta rede é denominada de 4-3-1, pois apresenta 4 nós de entrada, 3 camadas ocultas escondidas (cada uma com 5 neurônios) e 1 neurônios de saída.

**Figura 3** - Configuração da rede neural para o modelo 4-3-1.



Nomenclatura: “ $R$ ” representa as variáveis de entrada; “ $Out$ ” a variáveis de saída; “ $p$ ” representa o vetor de entrada, “ $a$ ” o vetor de saída, “ $M$ ” o número de camadas ocultas da rede, “ $b$ ” o vetor de polarização, “ $f$ ” a função de transferência, e “ $W$ ” a matriz de peso. Fonte: Software MATLAB adaptado segundo HAGAN et al, 2014.

**Fonte:** Elaborado pelos autores (2021).

### 2.2.3. Teste para validação do treinamento

Para validar a fase de aprendizado supervisionado das redes neurais, selecionou-se três dias para teste, com o intuito de verificar a qualidade da estimacão para condições distintas de tempo atmosférico: a) dia com céu aberto, caracterizado por níveis elevados de radiação solar global, com ausência de nuvens (denominado de dia típico 1); b) dia com presença de nebulosidade, caracterizado com níveis elevados de radiação solar e com presença de passagens de nuvens no local de medição (dia típico 2); e c) dia nublado, caracterizado com baixa radiação solar e umidade elevada em decorrência de ocorrência de precipitação atmosférica (dia típico 3). A validação foi conduzida para os dias agrupados, simulando dias consecutivos com as condições de tempo atmosférico indicadas anteriormente.

Para a etapa de treinamento da rede neural foram utilizados 81 dias de medição, de 21 de outubro de 2017 a 10 de março de 2018. A etapa de validação da RNA foi conduzida para os dias típicos acima descritos, não sendo estes utilizados no treinamento da rede (amostra independente). Utilizou-se as taxas padrões estabelecidas pelo MATLAB para treinamento (70%), teste (15%) e validação (15%), com intervalos definidos aleatoriamente pelo software. Dados identificados com falhas nos sensores foram suprimidos da amostra de treinamento. Não foram aplicados procedimentos de normalização nos dados brutos uma vez que a própria rede neural do software MATLAB dispõe de blocos de pré-processamento/ pós-processamento para tratamento das entradas/ saídas em valores que são mais adequados para treinamento de rede.

### 2.2.4. Validação da Estimacão

Os valores de IBUTG computados a partir das medições de campo e os estimados pelas RNA foram comparados por meio dos seguintes indicadores estatísticos: (1) parâmetros da equação de regressão linear ( $Y = a + bX$ ), em que Y é o IBUTG estimado pela RNA e X é o IBUTG medido; (2) do coeficiente de determinacão ( $R^2$ ) (Equação 3), que indica a proporção da variância na variável dependente (Y) que é prevista ou explicada pela regressão linear e a variável preditora (X, também conhecida como variável independente); (3) Raiz do Erro Quadrático Médio (RMSE, *Root Mean Squared Error* em inglês) que representa o desvio padrão dos erros (Equação 4), ou seja, um valor que representa a

diferença entre os valores estimados e os valores calculados de IBUTG; O RMSE apresenta a mesma dimensão da variável analisada; (4) Erro Absoluto Médio (EAM, *Mean Absolute Error* em inglês) (Equação 5), cometido durante o período diurno e noturno no procedimento de calibração, este também expresso na dimensão da variável analisada (WILLMOTT, 1982).

A estimação destes índices foi utilizada para avaliação do desempenho das redes testadas. No caso de uma correlação perfeita entre os dados estimados e medidos, sem viés,  $a = 0$  e  $b = 1$ ,  $R^2 = 1$ ,  $EAM = 0$  e  $RMSE = 0$ . Nas Equações 3 a 5,  $P_i$  corresponde ao valor estimado (previsto),  $O_i$  o valor medido (observado),  $\bar{O}$  o valor médio medido (observado),  $\bar{P}$  o valor médio estimado (previsto) e  $N$  o número de medições consideradas nas predições.

$$(3) \quad R^2 = \left\{ \frac{\sum_1^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_1^N (O_i - \bar{O})^2} \sqrt{\sum_1^N (P_i - \bar{P})^2}} \right\}^2$$

$$(4) \quad MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{N}$$

$$(5) \quad RMSE = \sqrt{\frac{(\sum_{i=1}^n (P_i - O_i)^2)}{N}}$$

### 3. RESULTADOS E DISCUSSÕES

Na Tabela 2 são apresentadas as configurações e os modelos de redes neurais testados para os dias típicos pesquisados. Em termos de desempenho, nota-se que as estimativas expressas por meio dos coeficientes de determinação para os dias agrupados foram elevadas ( $R^2 > 0,8098$ ), com erros médios quadráticos (RMSE), alcançando valores inferiores a  $0,6^\circ\text{C}$  de IBUTG, exceção ocorrendo na rede 4-3-1 com cinco neurônios, onde o erro ultrapassou  $1,0^\circ\text{C}$  de IBUTG (ver linha em vermelho), caracterizando-se como a rede de pior estimação.

O melhor desempenho para os dados agrupados foi alcançado com a configuração da rede modelo 4-3-1 com dez neurônios (ver linha em azul). Com essa configuração, o erro médio quadrático se reduziu para  $0,27^\circ\text{C}$  e o coeficiente de determinação se elevou para 0,9876.

É possível identificar comportamento padrão para as estimativas feitas pela RNA para as configurações de redes com cinco e quatro variáveis de entrada, camada oculta variável e cinco neurônios. Nota-se redução no RMSE e elevação do coeficiente de determinação à

medida que a quantidade de camadas ocultas se eleva até três, com posterior inversão destes índices a partir da introdução da quarta camada oculta. Para as redes com 10 neurônios, o comportamento é o inverso, ou seja, elevação da RMSE e redução do coeficiente de determinação até três camadas e inversão deste comportamento para aquelas com quatro camadas ocultas.

As configurações de redes com quatro variáveis de entrada (que não inclui a pressão atmosférica) e cinco neurônios nas camadas ocultas em média conduziram a desempenho superior em relação às redes equivalentes com cinco variáveis de entrada e cinco neurônios. Por outro lado, aquela com quatro variáveis de entrada e dez neurônios foram, em média, observados os piores desempenhos. Diante disso, o melhor desempenho foi encontrado na rede com quatro variáveis de entrada, três camadas ocultas e cinco neurônios, como relatado anteriormente.

Uma análise mais detalhada para os dias típicos de forma individual para as estimativas das RNAs revela que os menores RMSE foram em média quantificados no dia em que há ocorrência de precipitação ( $0,15^{\circ}\text{C}$ ) (dia típico 3). Isso decorre do fato deste dia não apresentar grandes amplitudes higrotérmicas em decorrência da baixa intensidade de entrada de radiação solar e umidade do ar próxima a de saturação, o que de certa forma facilita as estimativas pela RNAs, uma vez que a  $T_{bu}$  e  $T_g$  são pouco afetados nesta condição.

Por outro lado, no dia de céu aberto (dia típico 1) são observados em média os maiores valores de RMSE em decorrência das maiores intensidades de entrada de radiação solar ( $0,56^{\circ}\text{C}$ ), o que provoca maiores amplitudes no termômetro de bulbo úmido em decorrência da grande variação higrotérmica, bem como no de temperatura de globo devido a incidência de radiação direta e difusa.

No dia com grande nebulosidade (dia típico 2), o valor de RMSE se comportou de forma intermediária ( $0,34^{\circ}\text{C}$ ) uma vez que o constante sombreamento dos termômetros de bulbo úmido e de globo, em decorrência das passagens das nuvens, provoca maior oscilação nas intensidades registradas para o  $T_{bu}$  e  $T_g$ .

Quanto ao coeficiente de determinação, os maiores valores médios ocorreram no dia típico 2 (0,9725) e menor no dia típico 1 (0,9594), com valor intermediário no dia típico 3 (0,9645). Este fato relaciona-se dispersão entre dados medidos e estimados, conforme relatado nas subsequentes análises.

Em termos de desempenho individual, configurações específicas de redes forneceram os melhores desempenhos em termos de RMSE (indicados em laranja) e coeficiente de determinação ( $R^2$ ) (indicados em verde). No entanto, a escolha da configuração de rede deve se dar por aquela que minimiza o erro da estimativa e maximiza o coeficiente de determinação para a condição de dados agrupados, uma vez que a proposta é disponibilizar a técnica de RNA para fins de gerenciamento das condições de estresse ao calor a céu aberto, onde os dados serão monitorados em plataforma de forma contínua.

Em virtude de seu desempenho, discute-se o comportamento da estimativa do IBUTG para a configuração de rede 4-3-1, cinco neurônios na camada oculta, com menor erro médio quadrático. Nos casos discutidos na sequência, os valores para os parâmetros da equação de regressão (a e b) foram altamente significativos ( $P < 0,01$ ).

**Tabela 2** - Configuração e desempenho dos modelos de redes neurais testados

Configuração				Coeficiente de determinação ( $R^2$ )				Erro médio Quadrático – RMSE (°C)				
R	M	N	Out	Rede	dia 1	dia 2	dia 3	Agrupado	dia 1	dia 2	dia 3	Agrupado
5	1	5	1	5-1-1	0,9732	0,9712	0,9582	0,9626	0,8021	0,3481	0,1579	0,5130
5	2	5	1	5-2-1	0,9918	0,9716	0,9626	0,9860	0,3421	0,3525	0,1374	0,2945
5	3	5	1	5-3-1	0,9900	0,9738	0,9620	0,9864	0,3583	0,3300	0,1434	0,2932
5	4	5	1	5-4-1	0,9841	0,9732	0,9563	0,9797	0,5275	0,3460	0,1590	0,3756
5	1	10	1	5-1-1	0,9864	0,9736	0,9551	0,9825	0,4528	<b>0,3297</b>	0,1524	0,3351
5	2	10	1	5-2-1	0,9859	0,9740	0,9628	0,9829	0,4651	0,3330	0,1396	0,3400
5	3	10	1	5-3-1	0,9495	0,9726	0,9033	0,9543	0,8456	0,3437	0,2237	0,5426
5	4	10	1	5-4-1	<b>0,9930</b>	0,9726	0,9647	0,9870	0,3309	0,3472	0,1364	0,2879
4	1	5	1	4-1-1	0,9789	0,9702	0,9667	0,9769	0,5462	0,3489	0,1303	0,3817
4	2	5	1	4-2-1	0,9908	<b>0,9746</b>	0,9629	0,9868	0,3406	0,3327	0,1375	0,2861
<b>4</b>	<b>3</b>	<b>5</b>	<b>1</b>	<b>4-3-1</b>	<b>0,9920</b>	<b>0,9724</b>	<b>0,9659</b>	<b>0,9876</b>	<b>0,3060</b>	<b>0,3342</b>	<b>0,1317</b>	<b>0,2724</b>
4	4	5	1	4-4-1	0,9797	0,9718	0,9616	0,9809	0,4869	0,3541	0,1461	0,3577
4	1	10	1	4-1-1	0,9857	0,9728	<b>0,9694</b>	0,9847	0,3926	0,3406	<b>0,1259</b>	0,3088
4	2	10	1	4-2-1	0,9864	0,9720	0,9657	0,9841	0,3910	0,3472	0,1337	0,3116
<b>4</b>	<b>3</b>	<b>10</b>	<b>1</b>	<b>4-3-1</b>	<b>0,7031</b>	<b>0,9736</b>	<b>0,9673</b>	<b>0,8098</b>	<b>1,8800</b>	<b>0,3422</b>	<b>0,1347</b>	<b>1,1060</b>
4	4	10	1	4-4-1	0,9853	0,9724	0,9675	0,9813	0,4971	0,3400	0,1322	0,3560

Nota: Laranja – Redes com melhor desempenho em termos de RMSE; Verde – Redes com melhor desempenho em termos de  $R^2$ ; Azul – Rede melhor desempenho com dados agrupados; Vermelho – Rede pior desempenho com dados agrupados

Fonte: Elaborado pelos autores (2021).

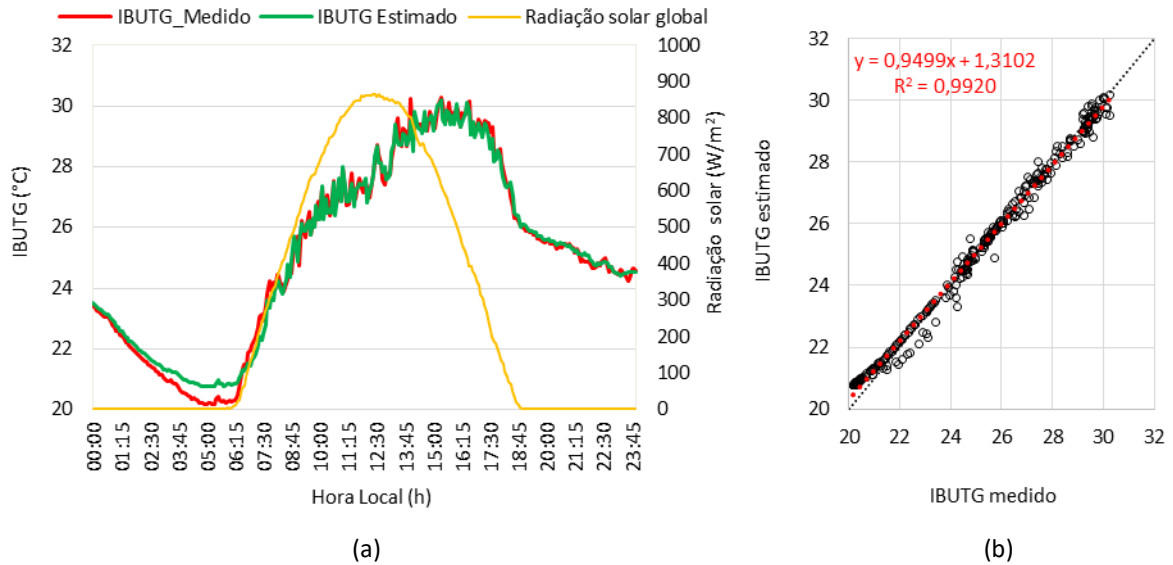
Para o dia típico 1, com condição de céu aberto, é possível observar que o IBUTG estimado pelo RNA acompanha o ciclo diário do IBUTG medido com adequada precisão (Figura 4a). Nota-se que durante o período noturno (das 19 às 24h) há tendência dos valores de IBUTG estimados ficarem sobrestimado com MAE de  $-0,20^{\circ}\text{C}$  (erro médio percentual de 1,63%), porém, durante a madrugada (0 às 6h) o valor eleva-se para  $-0,34^{\circ}\text{C}$  (erro médio percentual de 0,41%). No diurno (7 às 17h), não se observa um comportamento padrão, ora as RNA sobrestimando ora subestimando os valores de IBUTG, com MAE de  $0,25^{\circ}\text{C}$  (erro médio percentual de 0,93%), superior ao noturno, porém, inferior ao observado durante a madrugada.

O tempo de resposta dos sensores de bulbo seco e de umidade relativa do ar captam as variações ambientais de forma diferenciada daquelas observadas nos termômetros de globo e de bulbo úmido, uma vez que estes expressam o efeito combinado das variáveis físicas do ambiente. O termômetro de bulbo úmido natural responde à evaporação que ocorre no ambiente, sendo influenciado pelas condições de temperatura e umidade do ar, bem como pela presença ou ausência de ventilação e de radiação solar. Já a temperatura de globo representa o efeito combinado do calor radiante/ radiação solar, da velocidade e temperatura do ar do ambiente onde esse termômetro está instalado (CALLEJAS, 2012). Por sua vez, a umidade relativa estimada por meio de um higrômetro utilizado na pesquisa decorre da utilização de um sensor capacitivo, enquanto o de bulbo úmido, por meio de sensor digital embebido em um cordão de pano úmido.

Diante disso, estes termômetros apresentam tempo de resposta diferente às variações higrotérmicas, o que ajuda a justificar as diferenças encontradas. Não se descarta também que estes desvios podem estar associados às incertezas de medidas dos diferentes sensores usados na pesquisa. Apesar disso, o RMSE encontrado foi de  $0,31^{\circ}\text{C}$  para esse dia, com o modelo linear explicando 99,20% da variância da variável dependente, no caso o IBUTG medido (Figura 4b).



**Figura 4** - (a) Ciclo diário do IBUTG e (b) correlação entre os dados medidos e estimados para o Dia Típico 1 (dia de céu aberto).

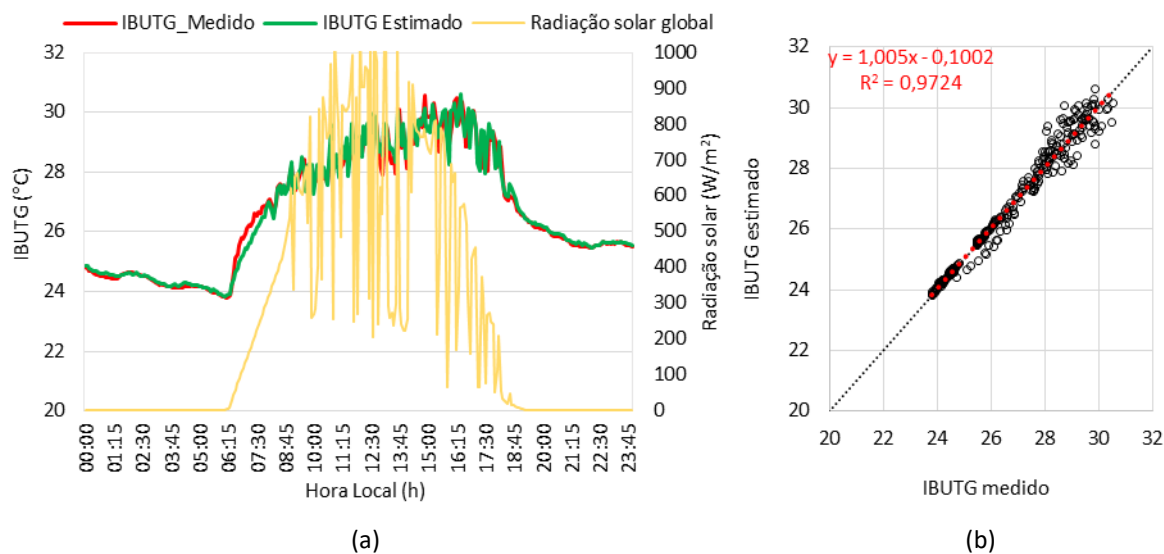


**Fonte:** Elaborado pelos autores (2021).

Para o dia típico 2, com presença de passagem de nuvens ao longo do dia, nota-se que a RNA consegue reproduzir de forma satisfatória as abruptas variações térmicas ocasionadas no IBUTG pelo bloqueio à entrada da radiação solar em virtude da presença de nebulosidade (Figura 5a). Durante o período noturno também se observa tendência dos valores de IBUTG estimados ficarem sobrestimados, com MAE de  $-0,05^{\circ}\text{C}$  (erro médio percentual de 0,25%), inferior ao observado no dia típico 1, de onde se pressupõe que possa ter ocorrido influência de alguma anomalia térmica, influenciando os sensores no período noturno naquele dia. No diurno, também não se observou um comportamento padrão, ora a RNA sobrestimando ora subestimando os valores de IBUTG, com MAE de  $0,38^{\circ}\text{C}$  (erro médio percentual de 1,38%), superior ao noturno e ao erro médio encontrado no dia típico 1.

A elevação do erro é decorrente das variações térmicas impostas pela passagem das nuvens que afetam as respostas dos sensores de  $T_{bu}$  e  $T_g$ , sendo que os sensores apresentam resposta mais lenta às estas variações se comparados aos sensores  $T_{bs}$  e de umidade relativa. Esse comportamento se reflete não só na maior dispersão dos dados observada na correlação entre o IBUTG medido e estimado, mas também na elevação do erro médio quadrático ( $0,3341^{\circ}\text{C}$ ) e na redução do coeficiente de determinação ( $R^2=0,9724$ ) (Figura 5b).

**Figura 5** - (a) Ciclo diário do IBUTG e (b) correlação entre os dados medidos e estimados para o Dia Típico 2 (dia com nebulosidade).



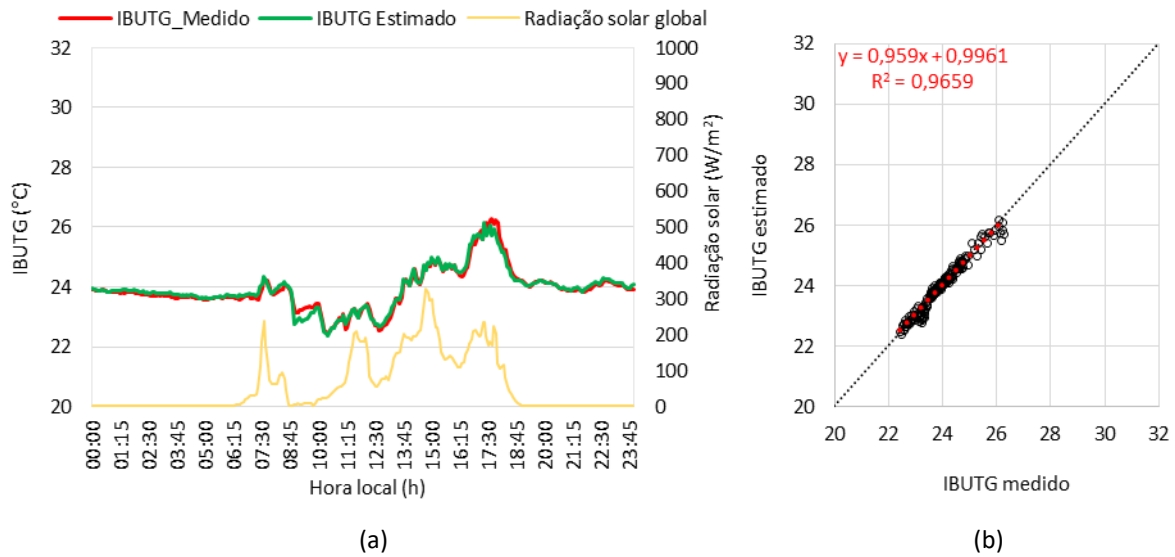
**Fonte:** Elaborado pelos autores (2021).

Para o dia típico 3, nublado durante todo o dia, nota-se que a RNA também conseguiu reproduzir de forma satisfatória as variações higrótérmicas ocasionadas no IBUTG pela presença de precipitação (Figura 6a). Assim, como nos dias anteriores, no período noturno observa-se a tendência dos valores de IBUTG estimados ficarem sobrestimados com MAE de  $-0,06^{\circ}\text{C}$  (erro médio percentual de 0,25%), aproximando-se ao valor determinado para o dia com nebulosidade. Durante o período diurno, há maior frequência de ocorrência da RNA subestimar os valores de IBUTG, com poucos horários ocorrendo superestimava, com MAE de  $-0,12^{\circ}\text{C}$  (erro médio percentual de 0,52%), valor inferior aos observados nos dias típicos 1 e 2.

A redução do erro está associada a menor intensidade observada para a radiação solar nesse dia, o que não induz abruptas variações térmicas, mas também pelo fato da umidade do estar próxima a de saturação, o que não induz grandes variações nos sensores de Tbu.

A dispersão dos dados observada na correlação entre o IBUTG medido e estimado é maior do que no dia típico 1, porém menor do no dia típico 2, com o menor erro médio quadrático para os dias pesquisados ( $0,13^{\circ}\text{C}$ ) e com coeficiente de determinação inferior aos dias típicos 1 e 2 ( $R^2 = 0,9659$ ) (Figura 6b).

**Figura 6** - a) Ciclo diário do IBUTG e (b) correlação entre os dados medidos e estimados para o Dia Típico 3 (dia de céu nublado).



Fonte: Elaborado pelos autores (2021).

## 4. DISCUSSÕES

O efeito da redução do RMSE e elevação do coeficiente de determinação à medida que a quantidade de camadas ocultas se eleva nas redes, com posterior saturação a partir de um determinado valor de número de neurônios, também foi verificado por Kaiho, Takamatsu e Itoh (2019). Os autores variaram em sua pesquisa o número de camadas ocultas (de 2 a 4) e incrementaram o número de neurônios em cada camada (10, 20, 50, 100 e 200), com intuito de identificar a melhor configuração das RNAs para as estimativas. Constataram que para três e quatro camadas, os desempenhos foram similares, com melhoria no desempenho para RNAs com até 20 neurônios. Quantidades superiores elevaram o RMSE e reduziram o coeficiente de determinação.

Em relação a RNA testada para os dias típicos (com três camadas e cinco neurônios em cada), verifica-se que esta proporcionou elevada correlação entre os dados medidos e estimados, com coeficiente  $b$  se aproximando da unidade, apesar da existência de desvio em relação à origem uma vez que  $a \neq 0$ . Os modelos lineares foram capazes de explicar satisfatoriamente a variância da variável dependente ( $R^2 > 0,9659$ ), todos com adequado nível de significância ( $P < 0,01$ ). Kaiho, Takamatsu e Itoh (2019) utilizaram uma RNA com três camadas e 20 nós para obter uma adequada estimativa da variável  $T_g$ , a qual foi posteriormente utilizada para a estimativa do IBUTG. O uso dessa configuração de rede conduziu a um coeficiente de determinação de 0,78 e um desvio padrão médio de 1,71 °C

para o Tg, que aplicado ao cálculo do IBUTG, conduziu a um erro de 1,0 °C, muito superior ao observado nesse trabalho.

Por outro lado, Mahgoub, Gowid e Ghani (2020), utilizando-se de variáveis de entrada e estrutura redes similares às utilizadas nessa pesquisa, verificaram que a técnica RNA foi capaz de reduzir o erro das estimativas do IBUTG obtido a partir de imagens termográficas. A RNA com uma única camada e 35 nós conduziu a uma adequada precisão para as estimativas, com erro médio máximo do IBUTG derivado a partir das imagens termográficas se reduzindo de 6,65% para 1,38%. Similarmente, nessa pesquisa o erro médio percentual não excedeu 1,63%, o que indica a viabilidade da técnica para a estimativa do referido índice.

Em relação às variações do RMSE e dos coeficientes de determinação para os dias típicos pesquisados, verifica-se que estes se aderem ao observado por De Paula et al. (2021), onde o modelo proposto para RNA para a previsão da temperatura do ar também conduziu a variações no RMSE (entre 0,01°C a 0,20°C) e no R<sup>2</sup> (de 0,88 a 0,99), explicado em razão das variações das condições sinópticas de tempo atmosférico, assim como ocorreu nessa pesquisa.

O maior RMSE quantificado na pesquisa se comparado ao dos autores decorre do fato do índice IBUTG ser uma variável dependente de fluxos radioativos, convectivos e latentes, enquanto a variável temperatura do ar, mais dependente das trocas térmicas convectivas (CALLEJAS et al., 2016). Portanto, as análises evidenciam a viabilidade da estimativa do índice IBUTG por meio do uso de redes neurais, o que pode fomentar o uso da técnica para monitoramento preventivo do risco ocupacional ao estresse térmico ao calor através da sua implantação em uma plataforma de monitoramento automático.

O clima urbano pode ser representado por três componentes: uma regional, uma local devida aos fatores não urbanos (efeitos topográficos, por exemplo) e finalmente aquela decorrente propriamente das condições urbanas (LOWRY, 1977). Nesse sentido, para uma abrangência mais geral das estimativas, com enfoque mais no comportamento de mesoescala do que microclimático, recomenda-se que as medições meteorológicas sejam feitas por meio de estações que estejam influenciadas pelas duas primeiras componentes.

Medições em áreas específicas da cidade, apesar de serem mais precisas, uma vez que os sensores de temperatura ou umidade ficam influenciados pela parcela de área no seu

entorno imediato, restringem a extensão das estimativas por parte das redes devido ao conceito de *footprint* das estações meteorológicas, onde a estimativa fica limitada a algumas centenas de metros no entorno da estação (OKE, 2006).

## CONSIDERAÇÕES FINAIS

Com a finalidade de verificar a viabilidade de se utilizar a técnica de redes neurais, para estimar o nível de exposição ocupacional ao calor de trabalhadores, que desempenham atividades em condição de céu aberto sem fonte artificial de calor, conduziu-se medições meteorológicas de forma síncrona com as variáveis físicas ambientais de temperatura de bulbo úmido e temperatura de globo, o que permitiu determinar o índice IBUTG, indicador utilizado NR.º 9 e NR.º 15 para avaliar o nível de estresse térmico ao calor.

As estimações proporcionadas pelas RNAs testadas permitiram demonstrar a viabilidade técnica de estimar o IBUTG com adequada precisão a partir de dados meteorológicos, usualmente medidos nas estações sem a utilização dos termômetros especificados pela norma. Para a rede de melhor desempenho, o RMSE médio foi inferior a 0,27°C, com elevado coeficiente de determinação ( $R^2 = 0,9876$ ), o que indica que o modelo linear explica 98,76% da variância da variável dependente a partir do regressores, o que garante uma adequada precisão para fins de avaliação da exposição ao calor. Além disso, a técnica foi efetiva em estimar o referido índice para as principais condições de tempo atmosférico aos quais os trabalhadores, que realizam suas atividades a céu aberto, estão expostos, o que a torna viável para fins de monitoramento do estresse térmico ocupacional ao calor.

A recomendação é que as medições meteorológicas sejam feitas em condições sinópticas que capturem apenas as componentes regional e local do clima, preferencialmente a partir de medições realizadas fora dos limites da cidade, com intuito de se obter condições de estresse ao calor em termos de mesoescala, sem a componente urbana.

Medições urbanas, apesar de mais precisas, podem ser realizadas, mas elas restringem o alcance da validade das medições devido ao *footprint* dos sensores, necessitando assim a instalação de várias estações na cidade para representatividade do estresse térmico nas diferentes áreas urbanas. Um fator importante a ser destacado é que estas estimativas não podem ser usadas com fins de caracterização quanto à exposição

ocupacional do trabalhador ao calor (caracterização de insalubridade), visto que a NR.º 15 estabelece procedimento específico por meio de laudo técnico.

A estimação do IBUTG a partir de uma estação meteorológicas por meio de uso da técnica de redes neurais artificiais pode ser utilizada para o monitoramento da exposição ocupacional a céu aberto nas cidades, servindo como uma estratégia de orientação do gerenciamento dos riscos ocupacionais ao quais os trabalhadores estão expostos.

Assim, os dados de tempo atmosférico coletados em tempo real nas estações automáticas podem ser usados para o desenvolvimento de um sistema de emissão de alertas visando à adoção de medidas de controle por parte dos empregadores ou pelos próprios trabalhadores, com vistas a adotar medidas de limitação da exposição ocupacional, e consequentemente, redução dos possíveis danos à saúde dos trabalhadores.

## AGRADECIMENTOS

Os autores agradecem ao CNPq e a FAPEMAT (Fapemat.445139) pelo suporte financeiro.

## REFERÊNCIAS

AGUIRE, L. A. **Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais**. Belo Horizonte: Editora UFMG, 2007. 728 p.

AMORIM, A. ELOÁ B.; LABAKI, L. C.; MAIA, P. A.; BARROS, T. M. SANTIAGO; & MONTEIRO, L. R. Exposição ocupacional ao calor em atividades a céu aberto na construção de estruturas de edifícios. **Ambiente Construído**, v.20, n.1, p.231-245, 2019. Disponível em: <https://doi.org/10.1590/s1678-86212020000100371>. Acesso em: 15 fev. 2021.

ATTHAJARIYAKUL, S.; LEEPHAKPREEDA, T. Neural computing thermal comfort index for HVAC systems. **Energy Conversion and Management**, v. 46, n. 15-16, p. 2553–2565, 2005. Disponível em: <https://doi.org/10.1016/j.enconman.2004.12.007>. Acesso em: 15 fev. 2021.

ANOCHI, Juliana Aparecida. **Previsão climática de precipitação por redes neurais autoconfiguradas**. 2015. Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.

Ministério do Trabalho e Emprego. Portaria n° 3214 de 8 de junho de 1978: Normas Regulamentadoras relativas à segurança e medicina do trabalho. **NR.º 15 – Atividades e operações insalubres**, 1978a.

Ministério do Trabalho e Emprego. Portaria n° 3214 de 8 de junho de 1978: Normas Regulamentadoras relativas à segurança e medicina do trabalho. **NR.º 09 – Programa de Prevenção de Riscos Ambientais**, 1978b.

BIANCHI, E. C. **Estimativa da energia elétrica gerada por um sistema fotovoltaico utilizando Redes Neurais Artificiais**. 2018. 126f. Dissertação (mestrado) – Universidade Federal de Mato Grosso, Faculdade de Arquitetura, Engenharia e Tecnologia, Cuiabá, 2018.

BORGES, V. C. A. L.; CALLEJAS, I. J. A.; DURANTE, L. C. Thermal sensation in outdoor urban spaces: a study in a Tropical Savannah climate Brazil. **Int J Biometeorol**, v.64, p.533–545, 2020. Disponível em: <https://doi.org/10.1007/s00484-019-01830-x>. Acesso em: 25 jan. 2021.

BUDD, G. M. Wet-bulb globe temperature (WBGT) - its history and its limitations. **Journal of Science and Medicine in Sport**, v.11, n.1, p.20-32, 2008. Disponível em: <https://doi.org/10.1016/j.jsams.2007.07.003>. Acesso em: 15 fev. 2021.

CALLEJAS, I. J. A. **Mapeamento do índice de bulbo úmido termômetro de globo (IBUTG) em região de clima tropical continental**. 2012. 40 f. Monografia (Especialização) – Faculdade de Arquitetura, Engenharia e Tecnologia, Universidade Federal de Mato Grosso, Cuiabá, 2012.

CALLEJAS, I. J. A.; NOGUEIRA, M. C. J. A.; BIUDES, M. S.; DURANTE, L. C. Seasonal Variation of Surface Energy Balance of a Central Brazil City. **Mercator**, v.15, n.3, p.85–106, 2016. Disponível em: <https://doi.org/10.4215/RM2016.1503.0006>. Acesso em: 12 fev. 2021.

CAMELO, Henrique do Nascimento; LUCIO, Paulo Sérgio; LEAL JUNIOR, João Verçosa. Modelagem da Velocidade do Vento Usando Metodologias ARIMA, HOLT-WINTERS e RNA Na Previsão de Geração Eólica no Nordeste Brasileiro. **Revista Brasileira de Climatologia**, v. 21, p.449–466, 2017. Disponível em: <https://dx.doi.org/10.5380/abclima.v21i0.48565>. Acesso em: 15 jan. 2021.

CARVALHO, Roberto Luís da Silva; DELGADO, Angel Ramon Sanchez. Estimativas Das Modelagens Por Redes Neurais Tipo GMDH E BOX-JENKINS para Séries de Temperaturas Máximas e Mínimas do Município de Ariquemes (RO). **Revista Brasileira de Climatologia**, v. 26, p.326–344, 2020. Disponível em: <https://doi.org/10.5380/abclima.v26i0.59145>. Acesso em: 10 jan. 2021.

CHAN, S. Y.; CHAU, C. K. Development of artificial neural network models for predicting thermal comfort evaluation in urban parks in summer and winter. **Building and Environment**, v. 164, 106364, 2019. Disponível em: <https://doi.org/10.1016/j.buildenv.2019.106364>. Acesso em: 15 jan. 2021.

CORREA, S. M. B. B. **Probabilidade e estatística**. 2. ed. Belo Horizonte: PUC Minas Virtual, 2003. 116p.

DE PAULA, Diana Carolina Jesus et al. Estimativa da Temperatura do Ar Microclimática em Cuiabá/MT Utilizando Redes Neurais. **Revista Brasileira de Climatologia**, v. 28, 2021. Disponível em: <http://dx.doi.org/10.5380/rbclima.v28i0.75304>. Acesso em: 20 jan. 2021.

ENGELBRECHT, A. P. **Computational intelligence: an introduction**. 2. ed. Wiley, 2007. 628p.

FERREIRA, P. M.; RUANO, A. E.; SILVA, S.; CONCEIÇÃO, E. Z. E. Neural networks based predictive control for thermal comfort and energy savings in public buildings. **Energy and Buildings**, v.55, p. 238-251, 2012. Disponível em: <https://doi.org/10.1016/j.enbuild.2012.08.002>. Acesso em: 20 jan. 2021.

GAO, L.; BAI, H. Neural Network Based Prediction of PMV Index. *In* Architectural Engineering Conference (AEI), September 17-20, Austin, Texas, United States, 2003. **Anais [...]**. American Society of Civil Engineers, 2003. Disponível em: [https://doi.org/10.1061/40699\(2003\)16](https://doi.org/10.1061/40699(2003)16). Acesso em: 25 jan. 2021.

GIAMPAOLI, Eduardo. **NHO 06 - Avaliação Da Exposição Ocupacional Ao Calor**. [s.n.], 2018. Web. Disponível em: <https://www.abho.org.br/nho-06-avaliacao-da-exposicao-ocupacional-ao-calor/>. Acesso em: 20 jan. 2021.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H.; JESÚS, O. **Neural network design**. 2. ed. Martin Hagan, 2014. 1012p.

HAYKIN, S. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2001. 898p.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 7726**. Ergonomics of the thermal environments: Instruments and methods for measuring physical quantities. International Standards Organization. Genebra, 1998.

KAIHO, Y.; TAKAMATSU, S.; e ITOH, T. Method of Estimating Heatstroke Risk Using Wristwatch-type Device, **Sensors and Materials**, v. 31, n. 12, p.4061-4068, 2019. Disponível em: <https://doi.org/10.18494/SAM.2019.2452>. Acesso em: 20 jan. 2021.

LOWRY, W. P. Empirical estimation of urban effects on climate: A problem analysis. **Journal of Applied Meteorology**, v.16, p.129-135, 1977. Disponível em: [https://doi.org/10.1175/1520-0450\(1977\)016<0129:EEOUEO>2.0.CO;2](https://doi.org/10.1175/1520-0450(1977)016<0129:EEOUEO>2.0.CO;2). Acesso em: 30 jan. 2021.

MAIA, P.A.; RUAS, A. C.; BITENCOURT, D. P. Wet-bulb globe temperature index estimation using meteorological data from São Paulo State, Brazil. **Int J Biometeorol**, v. 59, n. 10, p.1395-403, 2015. Disponível em: <https://doi.org/10.1007/s00484-014-0949-7>. Acesso em: 30 jan. 2021.

MAHGOUB, A. O.; GOWID, S.; GHANI, S. Global evaluation of WBGT and SET indices for outdoor environments using thermal imaging and artificial neural networks. **Sustainable Cities and Society**, v. 60, 102182, 2020. Disponível em: <https://doi.org/10.1016/j.scs.2020.102182>. Acesso em: 25 jan. 2021.

MATHWORKS. **MATLAB**. Disponível em: <https://www.mathworks.com/products/matlab.html>. Acesso em: 10 mar. 2021.

MELLIT, A; SAĞLAM, S; KALOGIROU, S. A. Artificial neural network-based model for estimating the produced power of a photovoltaic module. **Renewable Energy**, v.60, p.71-78. 2013. Disponível em: <https://doi.org/10.1016/j.renene.2013.04.011>. Acesso em: 15 mar. 2021.



MOUSTRIS, K.; NASTOS, P. T.; PALIATSOS, A. G. One-Day Prediction of Biometeorological Conditions in a Mediterranean Urban Environment Using Artificial Neural Networks, **Advances in Meteorology**, v. 2013, 538508, 2013. Disponível em: <https://doi.org/10.1155/2013/538508>. Acesso em: 20 mar. 2021.

MOUSTRIS, K.; TSIROS, I. X.; TSELIU, A. et al. Development and application of artificial neural network models to estimate values of a complex human thermal comfort index associated with urban heat and cool island patterns using air temperature data from a standard meteorological station. **Int J Biometeorol**, v.62, p.1265-1274, 2018. Disponível em: <https://doi.org/10.1007/s00484-018-1531-5>. Acesso em: 5 mar. 2021.

PALLADINO, D.; NARDI, I.; BURATTI, C. Artificial Neural Network for the Thermal Comfort Index Prediction: Development of a New Simplified Algorithm. **Energies**, v.13, 4500, 2020. Disponível em: <https://doi.org/10.3390/en13174500>. Acesso em: 5 mar. 2021.

OKE, T. R. **Initial guide to obtain representative meteorological observations at urban site. World Meteorological Organization**. Canadá: WMO, 2006. 47p.

ROSCANI, R. C.; BITENCOURT, D. P.; MAIA, P. A.; RUAS, A. C. Risco de exposição à sobrecarga térmica para trabalhadores da cultura de cana-de-açúcar no Estado de São Paulo, Brasil, **Cad. Saúde Pública**, v.33, n.3, e00211415, 2017. Disponível em: <http://dx.doi.org/10.1590/0102-311X00211415>. Acesso em: 10 mar. 2021.

SOUZA, Amaury de; PAVÃO, Hamilton Germano; OLIVEIRA, A. P. Garcia. Artificial Neural Networks: An Application In The Study Of Air Quality. **Revista Brasileira de Climatologia**, v. 13, 2014. Disponível em: <http://dx.doi.org/10.5380/abclima.v13i0.33066>. Acesso em: 15 mar. 2021.

WILLMOTT, C. J. Some comments on the evaluation of model performance. **Bulletin of the American Meteorological Society**, v. 63, n. 11, p.1309-1313, 1982. Disponível em: [https://doi.org/10.1175/1520-0477\(1982\)063<1309:SCOTEO>2.0.CO;2](https://doi.org/10.1175/1520-0477(1982)063<1309:SCOTEO>2.0.CO;2). Acesso em: 10 fev. 2021.