

## PROPOSTA DE REDE NEURAL ARTIFICIAL PARA ESTIMATIVA DO CONFORTO TÉRMICO

**Fernanda Marcielli Santos**

Universidade Federal de Mato Grosso, Programa de Pós-graduação em Física Ambiental  
Cuiabá, MT, Brasil  
[fernanda.santos@sou.ufmt.br](mailto:fernanda.santos@sou.ufmt.br)

**Carlo Ralph de Musis**

Universidade Federal de Mato Grosso, Programa de Pós-graduação em Física Ambiental  
Cuiabá, MT, Brasil  
[carlo.demusis@gmail.com](mailto:carlo.demusis@gmail.com)

### RESUMO

O artigo apresenta o desenvolvimento de um procedimento utilizando Rede Neural Artificial (RNA) para realizar a previsão do conforto térmico. Os dados utilizados na pesquisa foram disponibilizados no banco de dados da ASHRAE, que reúne dados climatológicos de trabalhos científicos mundiais. Para a arquitetura da RNA, optou-se por um modelo *Feed-Forward* (FF) com rede triangular de três camadas, otimizador NAdam com taxa de aprendizado de 0,01 e função de ativação ReLu em três camadas. Dividiram-se os dados em 70% para treinamento e 30% para teste, utilizando um *batch size* de 512 executando 1.500 *epochs*. Os parâmetros de entrada usados foram: índice de resistência térmica das vestimentas, taxa de metabolismo individual, temperatura do ar, umidade relativa do ar, velocidade do ar e temperatura externa mensal do ar, e o parâmetro de saída foi o conforto térmico. O desenvolvimento da rede neural foi realizado em linguagem Python utilizando as bibliotecas existentes (Tensorflow e Keras), sendo posteriormente disponibilizado no Github. Os resultados mostraram que a RNA ajustada apresentou um erro de 13,7%, considerada como tendo um bom ajuste para estimar a sensação térmica.

**Palavras-chaves:** Conforto térmico. Aprendizagem de máquina. Climatologia urbana.

### PROPOSAL FOR AN ARTIFICIAL NEURAL NETWORK TO ESTIMATE THERMAL COMFORT

#### ABSTRACT

The study presents the development of a procedure using an Artificial Neural Network (ANN) capable of predicting a thermal comfort model. The data used in the research were made available in the ASHRAE database, which gathers climatological data from world scientific studies. For the ANN architecture, we used a Feed-Forward (FF) model with a three-stage triangular network, an Adam optimizer with a learning rate of 0.01, and a ReLu activation function in the three stages. The data was divided into 70% for training and 30% for testing, using a batch size of 512 and running 1,500 epochs. The input parameters used were the thermal resistance index of the clothes, individual metabolism rate, air temperature, relative air humidity, air velocity, and monthly external air temperature; the output parameter was thermal comfort. The neural network development was conducted in Python using existing libraries (Tensorflow and Keras) and was later made available on GitHub. The results found that an adjusted ANN presented an error of 13.7%, considered a good fit for estimating thermal sensation.

**Keywords:** Thermal comfort. Machine learning. Urban climatology.

### INTRODUÇÃO

O conforto térmico individual é uma condição mental que expressa a sensação de bem-estar em relação à temperatura do ambiente. Quando uma pessoa está exposta a um ambiente e não sente nem frio, nem calor, não precisando recorrer a mecanismos de termorregulação corporal para se sentir bem, ela está em um estado de conforto térmico (ASHRAE/ANSI 55, 2017).

Essa percepção de conforto térmico leva em consideração aspectos subjetivos que representam a maneira como cada pessoa percebe o ambiente, com base em suas preferências individuais, que podem estar associadas a contextos culturais, expectativas térmicas e aclimação. Essas respostas psicológicas e fisiológicas são correlacionadas com os dados ambientais para determinar os padrões temporais e espaciais e permitir a avaliação do conforto térmico (LAMBERTS et al., 1997).

A sensação de conforto térmico individual em um ambiente, é influenciada pela taxa de metabolismo e pela atividade física desenvolvida, pelas vestimentas e pelas variáveis climáticas (OKE, 1982). Todas essas variáveis ativam os termorreceptores do corpo humano, provocando sensações particulares ou subjetivas, que levam à homeostase corporal. Nota-se que a faixa de temperatura que causa desconforto térmico é pessoal e depende da combinação de vários fatores.

O mecanismo de termorregulação mantém a temperatura corporal entre 36 e 37 °C. Quando esta cai abaixo desse valor, ocorre vasoconstrição, tremedeira, arrepios e aumento da taxa metabólica. Quando sobe, ocorre vasodilatação e produção de suor para dissipar o calor. Essa termorregulação é essencial para manter a homeotermia, ou seja, o equilíbrio da temperatura corporal. No entanto, quando o corpo não consegue mais manter esse equilíbrio a pessoa experimenta a sensação de calor ou frio, dependendo do ambiente em que se encontra e de sua adaptação às condições desfavoráveis (OKE, 1982).

Conforme Höpfe; Mayer (1987) e Benzinger (1969), o processo fisiológico do corpo humano conta com termorreceptores, que são sensores sensíveis à percepção das variáveis climáticas. Esses sensores enviam mensagens para o hipotálamo regular as trocas de calor do organismo com o meio ambiente. Quando está frio, ocorre o envio de estímulos elétricos através dos nervos simpáticos, provocando a vasoconstrição dos capilares da pele, reduzindo o fluxo de sangue superficial e mantendo o calor do corpo nos órgãos mais profundos. Esse estímulo também contrai os músculos eretores dos pelos para criar uma camada de ar que gera isolamento térmico. Também ocorrem estímulos nervosos para a contração da musculatura, tremores, que auxiliam na geração de calor no corpo. Quando está quente, pode ocorrer uma regulação hormonal controlada pelo hipotálamo, que induz a hipófise a secretar o hormônio tireoestimulante (TSH) fazendo com que aumente a taxa metabólica e mais calor seja produzido pelo corpo. Em um ambiente moderado, o sistema termorregulador corporal conserva a temperatura da pele, o fluxo sanguíneo e a transpiração para manter o equilíbrio térmico.

Fanger (1970) realizou estudos em câmaras climáticas e descobriu que a sensação térmica média relatada por um grupo de pessoas expostas ao mesmo ambiente térmico era influenciada por quatro variáveis físicas (temperatura do ar, temperatura média radiante, umidade do ar e velocidade do ar) e duas pessoais (índice de resistência térmica das roupas e taxa metabólica).

Com base nessas descobertas, foi criada a norma ISO 10551 (1995) de avaliação da influência do ambiente térmico por meio de escalas subjetivas de julgamento baseadas no balanço térmico do corpo humano. Assim, o conforto térmico poderia ser mensurado usando-se os índices: PMV (*Predicted Mean Vote*) e PPD (*Predicted Percentage Dissatisfied*). Essa norma permitiu avaliar o estresse térmico com base no equilíbrio térmico e medir a reação humana ante às variações microclimáticas, a fim de determinar as condições que produzem conforto térmico similar em todos aqueles que respondem à pesquisa. Com isso, foi possível padronizar os resultados para faixas de temperatura ideais em que as pessoas se sentiam confortáveis termicamente. Isso permite o controle térmico do ambiente construído para atender à avaliação de conforto térmico dos ocupantes da edificação.

Por ser mais difícil comparar fatores subjetivos individuais, as duas variáveis pessoais (índice de resistência térmica das roupas e taxa metabólica) tentam representar a resposta psicológica, subjetiva a cada indivíduo. De acordo com Oke (1982), as métricas de conforto térmico estão associadas a fatores físicos (relacionados aos processos de trocas térmicas e às variáveis climáticas), mas também a fatores psicológicos (associados às experiências pessoais e às respostas aos estímulos sensoriais) e fisiológicos (implícitos à resposta involuntária do organismo pela termorregulação corporal) e podem fornecer informações para determinar se o ambiente atende à expectativa térmica dos indivíduos.

Com fim de avaliar o conforto térmico em um ambiente, diversos pesquisadores realizam investigações científicas pelo mundo considerando as variáveis apresentadas acima e interpretam as sensações térmicas das pessoas agrupando os resultados de acordo com a semelhança das respostas em faixas de temperatura que são consideradas satisfatórias ou não para aquele grupo. Com isso, é possível determinar se o ambiente proporciona um conforto térmico adequado aos seus ocupantes.

Para fornecer acesso organizado aos dados de conforto térmico, vários artigos com indicadores foram compilados pela ASHRAE em um banco de dados chamado *Global Thermal Comfort Database*. Essa

compilação foi lançada em duas versões, a primeira em 1998 (I) com dados desde 1985, e a segunda em 2014 (II) atualizada em 2018. Ela contém 107.583 registros, sendo 25.616 do banco de dados I e 81.967 do banco de dados II.

Esse banco de dados é uma ferramenta valiosa para pesquisadores, profissionais e outras partes interessadas no estudo de conforto térmico em edifícios, fornecendo acesso a uma grande quantidade de dados e informações para apoiar a tomada de decisão e promover o projeto de edifícios energeticamente eficientes e confortáveis termicamente.

Os pesquisadores coletaram os dados das variáveis climáticas e avaliaram o conforto térmico em relação ao ambiente estudado, sendo coletados em 52 campos de estudo e 160 tipos diferentes de construções, para avaliar as métricas de conforto térmico. As pesquisas foram realizadas em 28 países ao redor do mundo e os dados foram agrupados pelo *Center for the Built Environment* (CBE) da Universidade da Califórnia em Berkeley e pelo *Indoor Environmental Quality Laboratory* (IEQLab) da Faculdade de Arquitetura da Universidade de Sydney. A equipe de compilação, liderada por Földváry et al. (2018), conduziu uma validação cruzada comparando cada conjunto de dados brutos com a publicação relacionada para verificar a consistência entre o conjunto de dados original e o banco de dados padronizado.

A interpretação desses dados pode ser desafiadora devido ao grande volume de informações, em situações em que a relação entre variáveis não é completamente compreendida, ou ainda em problemas que apresentam dificuldade de modelagem ou grande volume de dados para simulação (YASSIN et al., 2016). No entanto, o uso de ferramentas de Inteligência Artificial (IA), incluindo *machine learning*, permite mapear respostas subjetivas ao ambiente físico e identificar tendências ocultas nos dados. Uma possibilidade é que essa análise pode ser realizada com o auxílio de algoritmos de Redes Neurais Artificiais (RNAs), que têm demonstrado eficiência em diversas aplicações e estudos climatológicos. Esses algoritmos permitem simular processos e prever modelos com alta capacidade de generalização, aplicando-se inclusive a dados diferentes dos originais.

Segundo Mandic; Chambers (2001), o objetivo das RNAs é criar modelos matemáticos computacionais capazes de ajustar um modelo de acordo com a precisão satisfatória para generalizar o conhecimento aprendido e aplicá-lo em novas situações com sucesso. Vários pesquisadores têm utilizado RNAs para modelar dados de conforto térmico, sendo alguns exemplos descritos a seguir.

Grabe (2016) examinou o potencial das RNAs para melhorar a previsibilidade do conforto térmico usando a base de dados derivada do Projeto de Modelo Adaptativo RP-884. Os resultados mostraram que a RNA projetada teve um bom desempenho na previsão da distribuição de votos individuais da ASHRAE sob condições definidas, mostrando semelhança com o índice PMV, de Fanger. A acurácia observada foi de 53%.

Ketterer; Matzarakis (2016) realizaram uma comparação entre a modelagem por regressão linear múltipla e RNAs para o planejamento do ambiente urbano em Stuttgart, Alemanha, utilizando mapas térmicos gerados por transectos móveis e o índice PET (*Physiological Equivalent Temperature*), baseado no balanço térmico do corpo humano. Os resultados apontaram que a modelagem por RNA proporcionou uma performance superior em relação à regressão linear múltipla (SMLR), resultando em um modelo com melhor ajuste aos dados, considerando o coeficiente de correlação (R), o erro quadrático médio (RMSE), o erro percentual absoluto médio e a análise de resíduos para mediana e desvio padrão.

Moustris et al. (2018) utilizaram modelos de RNAs na cidade de Atenas (Grécia) para estimar os valores do índice PET relacionados ao calor urbano e às condições de Ilha de Frescor Urbano (IFU) em vários aglomerados urbanos. Os resultados indicaram que as RNAs apresentaram boa capacidade de estimar os valores de PET, o que sugere que esse modelo pode ser útil para a avaliação do conforto térmico em ambientes urbanos.

Chai et al. (2020) afirmam que os algoritmos de RNA são mais confiáveis do que o modelo de Fanger para a previsão de conforto térmico. Isso ocorre porque as RNAs permitem a identificação de padrões de semelhança não visíveis nas amostras de dados.

Com base nessas aplicações, destaca-se a eficiência da técnica de RNA como alternativa para contribuir com a predição do conforto térmico em ambientes analisados. Portanto, o objetivo deste trabalho é desenvolver uma RNA que preveja um modelo de conforto térmico, selecionando os parâmetros mais relevantes e ajustando os hiperparâmetros para avaliar sua acurácia. A justificativa para este estudo reside na necessidade de aprimorar as métricas de conforto térmico que podem ser

alcançadas com o uso de RNAs, a fim de verificar as preferências térmicas das pessoas em diferentes locais, considerando as variações na aclimação e utilizando um modelo de predição diferente do proposto por Fanger. Com isso, a disponibilização de códigos que usem RNAs para o estudo de conforto térmico pode auxiliar pesquisadores que possuem vários dados e desejam testar um código validado, fazendo os ajustes necessários de variação de parâmetros, o que facilitaria a análise.

## METODOLOGIA

Neste estudo, foi utilizada uma base de dados de experimentos com diferentes parâmetros, com base em experiências descritas na literatura, para desenvolver uma RNA robusta e capaz de generalizar bem para outros conjuntos de dados.

Utilizou-se a linguagem *Python* com as bibliotecas *TensorFlow* e *Keras* para rodar os algoritmos de *machine learning* nesta pesquisa. A RNA foi treinada no servidor virtual *PowerEdge R720*, com 200Gb de memória RAM e 32 núcleos de processamento para otimizar o tempo de processamento. A modelagem da RNA foi disponibilizada na plataforma GitHub para hospedagem de código-fonte no endereço: [https://github.com/demusis/pvmrna\\_ASHRAE](https://github.com/demusis/pvmrna_ASHRAE)

As RNAs são técnicas computacionais inspiradas na estrutura e no funcionamento dos neurônios biológicos, que são capazes de aprender com a experiência e de reconhecer padrões em dados complexos. São formadas por unidades de processamento chamadas neurônios artificiais, ou perceptrons, que se conectam entre si por meio de pesos e vieses (*bias*). Cada um deles possui uma função de ativação que determina se ele deve ou não transmitir um sinal para os neurônios seguintes, como nas sinapses nervosas. As RNAs podem ter diferentes arquiteturas, dependendo do número e da disposição das camadas de neurônios. Uma das arquiteturas mais comuns é a rede Feed-Forward (FF), na qual o sinal se propaga em uma única direção, da camada de entrada para a camada oculta e desta para a camada de saída, sem haver realimentação entre as camadas (KOVÁCS, 2006)

O aprendizado em uma RNA ocorre por meio da otimização dos seus parâmetros, que são ajustados de forma iterativa durante o processo de treinamento. A função de ativação é essencial nesse processo, pois ela realiza uma transformação não-linear do sinal de entrada, permitindo que a rede possa confrontar uma variedade maior de situações. A propagação dos sinais pela rede só é possível com a ajuda do gradiente de otimização, que é calculado com base no erro entre a saída atual e a saída desejada. (MANDIC; CHAMBERS, 2001, FAUSETT, 2006, GLOTOT; BORDES; BENGIO, 2011).

De acordo com Fausett (2006), no algoritmo de retropropagação do erro (*backpropagation*), o aprendizado ocorre por meio da apresentação repetida de todas as amostras do conjunto de treinamento, denominadas épocas (*epochs*). A atualização dos pesos e *bias* em lote (*batch*) é realizada após a apresentação de todas as amostras do conjunto de treinamento, permitindo estimar de forma mais precisa o gradiente. Esse processo é repetido por várias épocas até que o conjunto de pesos e *bias* estabilize e o erro de ajuste da estimativa obtido com o conjunto de treinamento seja minimizado.

Conforme Géron (2019), a topologia da rede neural é determinada pelos hiperparâmetros selecionados e afetam o esforço computacional do treinamento, sendo os mais usuais: número de camadas ocultas, número de neurônios em cada camada, otimizador para a conversão da função, taxa de aprendizado, função de ativação, tamanho do lote (*batch size*) e número de épocas. Em geral, são testadas várias configurações de hiperparâmetros para encontrar a melhor combinação que maximize o desempenho da rede neural.

Os métodos de otimização são responsáveis por atualizar os pesos da RNA de modo a minimizar a função de custo, também conhecida como função de perda (GÉRON, 2019). Esta é calculada com base na diferença entre a saída real e a saída calculada pela rede, e a partir dela, os pesos são ajustados para minimizar o erro. À medida que o valor da função de custo diminui, a precisão da saída calculada aumenta.

O otimizador é usado para calcular a previsão do modelo em termos de generalização, estabelecendo uma relação entre o grau de imprecisão e o grau de perda (PATTERSON; GIBSON, 2017). O algoritmo de retropropagação é responsável por calcular os gradientes e passá-los para o algoritmo de otimização, que por sua vez, altera os parâmetros e pesos da RNA para atingir a saída desejada. O NAdam é um método de gradiente descendente que minimiza a função de custo usando a taxa de aprendizagem e o gradiente, e é uma junção dos métodos Nesterov e Adam (GÉRON, 2019).



Outro hiperparâmetro importante na RNA é a taxa de aprendizado, que é utilizada como uma taxa de correção a cada época. Se a taxa for muito grande, pode levar à falta de convergência, enquanto se for muito pequena, o tempo de treinamento pode ser prolongado, já que o algoritmo terá que passar por muitas iterações para convergir (LECUN; BENGIO; HINTON, 2015).

De acordo com Géron (2019), a taxa de aprendizado ideal é aproximadamente metade da taxa máxima de aprendizado, acima da qual o algoritmo de treinamento diverge. Ela pode ser ajustada gradualmente, iniciando com um valor muito baixo e aumentando aos poucos. Normalmente, o número de iterações de treinamento não precisa ser ajustado, utilizando-se o *callback* para parada antecipada. É importante notar que a taxa de aprendizado ideal depende de outros hiperparâmetros, especialmente o tamanho do lote (*batch size*) que corresponde ao número de padrões apresentados à rede antes de os pesos serem atualizados. Portanto, quando qualquer hiperparâmetro é modificado, é necessário atualizar a taxa de aprendizado.

Para Géron (2019), é comum utilizar a potência de dois ( $2^a$ ) para definir o batch size, mas outros valores também podem ser usados. O tamanho do lote pode ter um impacto significativo no desempenho e no tempo de treinamento do modelo. Lotes de tamanhos grandes permitem acelerar o processamento utilizando aceleradores de hardware, como GPUs (*Graphics Processing Unit*), de modo que o algoritmo de treinamento verá mais instâncias por segundo. Porém, isso pode levar a instabilidades de treinamento, especialmente no início do treinamento, e o modelo resultante pode não generalizar tão bem quanto um modelo treinado com um tamanho de lote pequeno.

O autor destaca que é possível usar tamanhos de lote muito grandes (até 8.192) iniciando o treino com uma pequena taxa de aprendizado e aumentando gradualmente. Isso leva a um tempo de treinamento muito curto, sem comprometer a generalização do modelo. Entretanto, se o treinamento for instável, ou o desempenho final for decepcionante, recomenda-se utilizar um tamanho de lote menor. Além disso, é importante lembrar que a taxa de aprendizado ideal está relacionada ao tamanho do lote e outros hiperparâmetros, e deve ser atualizada sempre que houver alterações nesses parâmetros.

De acordo com Goodfellow; Bengio; Courville (2016), um dos principais desafios de uma boa RNA é selecionar fatores de entrada apropriados. Embora as RNAs possam lidar com modelos não-lineares, muitas variáveis de entrada podem ser utilizadas desde que haja amostras de treinamento suficientes. Contudo, é importante limitar o número de fatores de entrada para manter o tamanho da rede razoável e obter uma boa previsão.

Por outro lado, se os fatores de entrada forem selecionados de forma muito restrita, ou seja, apenas os fatores altamente relacionados à saída forem utilizados, a vantagem da modelagem da RNA em comparação com a regressão múltipla simples não será significativa. É importante, portanto, utilizar níveis significativos para selecionar fatores relevantes como variáveis de entrada na construção de modelos de RNA.

Após a calibração, a rede neural é submetida à etapa de validação. Nessa fase, um conjunto de dados que não foi utilizado no treinamento é utilizado para avaliar o modelo. São inseridos apenas os dados de entrada e a rede é solicitada a produzir os dados de saída estimados correspondentes. Em seguida, os dados estimados pela rede são comparados com os dados observados e o erro é calculado como a diferença entre eles, a fim de determinar se a rede está fornecendo resultados satisfatórios para o fenômeno estudado. (HAYKIN, 2001)

A amostra de validação é um conjunto independente de dados utilizado para avaliar a RNA final, como destacado por Géron (2019). Nessa etapa, os dados de entrada são fornecidos à rede e os dados de saída estimados são comparados com os dados observados, a fim de avaliar a capacidade preditiva do modelo. O erro resultante dessa comparação fornece uma estimativa da precisão da RNA na previsão do fenômeno em questão.

De acordo com Nguyen et al. (2021), uma proporção de 70:30 para conjuntos de dados de treinamento e para teste ou validação é considerada uma boa razão para o treinamento e validação de modelos. Essa proporção é consistente com outros trabalhos investigados pelos autores, que avaliaram diferentes proporções de treinamento/teste para modelos de *machine learning* e previsão espacial de deslizamentos de terra. Nesse recorte, concluíram que essa seria a relação ótima para obter o melhor desempenho. Porém, a proporção de treinamento e teste inicial que também foi testada é de 90:10 de treinamento e de teste ou validação, o que justifica avaliar qual a melhor proporção.

A fase de calibração é responsável por ajustar os parâmetros do modelo com base nos dados observados, enquanto a validação avalia o desempenho da rede em novas situações. A medida de

semelhança entre os dados observados e estimados é feita por meio do cálculo do erro estatístico. Durante a calibração, busca-se ajustar os parâmetros do modelo para obter o maior grau de semelhança possível, enquanto na validação verifica-se a confiabilidade e a coerência do modelo com a realidade (LECUN; BENGIO; HINTON, 2015).

Os parâmetros escolhidos para alimentar a entrada da RNA foram: índice de resistência térmica das roupas (clo), taxa de metabolismo (met), temperatura do ar (°C), umidade relativa do ar (%), velocidade do ar (m/s) e temperatura mensal do ar externa (°C). Esses parâmetros são comumente usados em várias métricas de conforto térmico baseadas em balanço térmico, o que torna mais fácil a comparação com outras métricas.

O pré-processamento de dados é um conjunto de técnicas de mineração de dados usadas para transformar dados brutos em formatos úteis e eficientes, que consiste na preparação dos dados com: limpeza, transformação e redução dos dados.

Na etapa de limpeza de dados, serão verificados valores faltantes e outliers (dados que se diferenciam drasticamente de outros, fugindo da normalidade e apresentando-se fora da curva). Na transformação dos dados ocorre a normalização dos dados (para deixar os valores dentro de limites preestabelecidos) e seleção de atributos. A redução dos dados representa o conjunto de dados que restou para análise da modelagem.

Nota-se que as variáveis de entrada possuem diferentes grandezas. Para que elas possam alimentar a RNA é necessário que elas sejam normalizadas, como parte da preparação de dados. O objetivo da normalização é mudar os valores das colunas numéricas no conjunto de dados para usar uma escala comum, sem distorcer as diferenças nos intervalos de valores nem perder informações. Usando-se a linguagem *Python*, e as bibliotecas *Pandas*, *TensorFlow*, *Sklearn*, *Seaborn* e *Keras*, é possível normalizar as variáveis.

Para a manipulação e análise de dados foi importada a biblioteca “*Pandas*” que oferece operações para manipular tabelas numéricas e séries temporais. Usando estatística descritiva pelo comando “*describe*” é gerada uma tabela fornecendo as estatísticas: “*count*”, “*mean*”, “*std*”, “*min*”, “25%”, “50%”, “75%” e “*max*”. Os dados com valores nulos são eliminados pelo comando “*dropna*”, com isso, a estatística “*count*” irá fornecer apenas dados que estejam preenchidos com algum valor. Esses parâmetros são, então, normalizados estatisticamente para convergir melhor. Com a função “*pairplot*” cada parâmetro de entrada é cruzado com outro e a partir disso são visualizadas as correspondências na matriz de gráficos de dispersão e as relações encontradas entre elas.

Durante o estudo, utilizou-se a base de dados da ASHRAE com 107.583 registros. Como os dados foram coletados a partir de diferentes estudos independentes, alguns parâmetros não possuíam informações em todos os registros. Assim, os intervalos específicos de células sem informações foram preenchidos com valores nulos, que foram posteriormente descartados. Por fim, selecionou-se os 58.654 registros completos para a modelagem da rede, o que representa 50,8% do total.

A saída da RNA usada foi o conforto térmico devido à sua associação direta com medidas físicas (temperatura do ar, velocidade do ar e umidade relativa do ar) e individuais (taxa de metabolismo e índice de resistência térmica da vestimenta) do modelo de Fanger.

Os parâmetros e hiperparâmetros foram definidos e testados para diminuir a incerteza quanto ao desempenho do modelo, com quatro tentativas limitadas para testar a melhor configuração de RNA, levando em consideração o alto custo computacional de cada execução.

Neste trabalho, foram usadas as seguintes configurações:

- Número de *epochs*: 1.500;
- *Batch size*: 512;
- Taxa de aprendizado: 0,01;
- Função de ativação: *ReLU* para todas as camadas;
- *Optimizer*: *Nadam*;
- Arquitetura de Rede: *Feed-Forward* (FF);

- Porcentagem de treinamento/teste: foram treinadas duas redes usando-se 90:10 e depois foram treinadas duas redes usando-se 70:30 (para comparar qual a melhor);
- Número de camadas: três (para garantir a não linearidade se usou rede triangular);
- Número de neurônios por camada: variável com base em um modelo triangular.

Foi usado o método estatístico de Monte Carlo, que utiliza a aleatoriedade de dados para gerar um resultado para um problema determinístico, como no caso, a relação entre o MAE e o número de neurônios.

Para monitorar o desempenho da RNA, será utilizado o coeficiente de correlação de Spearman. Este coeficiente é uma medida da dependência estatística entre duas variáveis, no caso entre as previsões da RNA e os valores reais do conjunto de dados. Valores próximos de 1 indicam maior precisão de tendências nos dados.

Através da comparação entre os resultados observados e estimados, é possível medir a acurácia do algoritmo, que corresponde à proporção de resultados corretos alcançados pelo classificador.

## RESULTADOS

Foram realizadas quatro análises para encontrar a melhor solução para a RNA proposta. Durante esse processo, foram realizadas algumas variações nos hiperparâmetros para avaliar se havia uma alteração significativa no erro, porém, o número de camadas e a variação do número de neurônios por camada foram mantidos constantes. Dessa forma, buscou-se explorar diferentes configurações de hiperparâmetros para identificar a melhor combinação para o modelo de RNA.

A função de ativação usada em todas as tentativas foi a ReLU e o otimizador usado foi o *NAdam*.

A rede neural com multicamadas profundas *Feed-Forward* (FF) foi treinada com a rede triangular construída por uma camada de entrada, uma camada oculta e uma saída. A taxa de aprendizagem na primeira e na segunda tentativas foi de 0.001 e na terceira e última tentativas foi de 0.01.

O número de épocas (*epoch*) teve como *early stopping* de 11 e máximo de 1500. A proporção de treinamento e teste foi de 90:10 nas primeira e segunda tentativas e de 70:30 nas terceira e quarta tentativas.

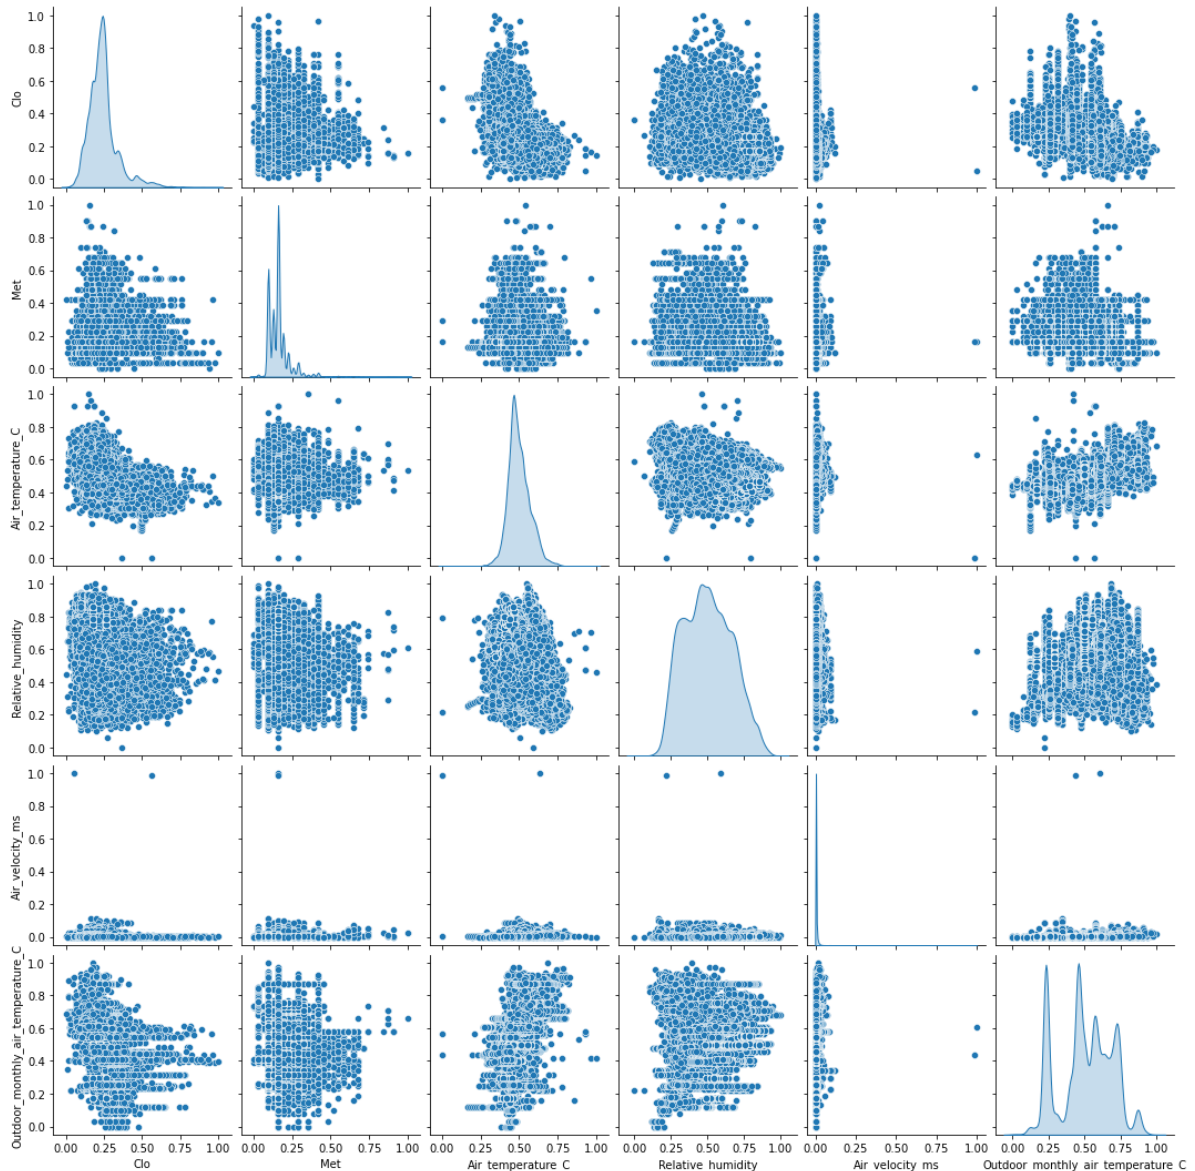
Após otimizações no código, na segunda tentativa a acurácia passou de aproximadamente 80% para 86%.

A diferença entre a terceira e a quarta tentativas foi basicamente a mudança do *batch size* de 400 para 512, respectivamente, conforme experiência de Géron, (2019) em suas pesquisas e trabalhos de utilizar a potência de dois ( $2^a$ , com  $a = 9$ ) para o *batch size*. Como ele explica que se pode usar qualquer valor, inicialmente foi testado valor menor e posteriormente testado a potência de dois, sem alteração significativa na RNA.

A Figura 1, apresentada, mostra uma matriz com gráficos de dispersão das variáveis de entrada da RNA com as funções de densidade de distribuição destas variáveis na diagonal principal. Na matriz, cada variável foi plotada em relação a todas as outras variáveis, permitindo avaliar a magnitude e direção da correlação entre elas. É importante observar que a correlação não implica causalidade, ou seja, uma correlação positiva entre duas variáveis não significa que uma causa a outra.

Esta análise da matriz de correlação permite avaliar visualmente a homogeneidade do grupo, sendo observado um número pequeno de *outliers*, justificando o uso das variáveis escolhidas para a entrada do modelo de RNA.

Figura 1 - Gráficos de dispersão das variáveis de entrada da RNA com as funções de densidade de distribuição destas variáveis na diagonal principal, 2022




Fonte: os autores, 2022.

A variação do desempenho da RNA foi avaliada por meio de uma análise de sensibilidade, na qual se simulou a rede neural variando o número de neurônios de 5 a 300 e aplicando validação cruzada *holdout* com uma proporção de 70:30, com nova aleatorização em cada iteração. O resultado desta análise foi apresentado no segundo gráfico da Figura 2, em que a abscissa é representada pelo número de neurônios ( $n$ ) e a ordenada pelo erro médio absoluto (MAE).

A construção do modelo ocorreu em duas etapas, utilizando um conjunto de dados de treinamento para ajustar os pesos da RNA e outro conjunto de dados de teste para avaliar o desempenho do modelo em dados desconhecidos. Utilizou-se o erro médio absoluto (MAE) como métrica de avaliação do desempenho do modelo em diferentes proporções de dados de treinamento e teste.



Figura 2 - Função MAE e sua derivada em relação ao número de neurônios, 2022

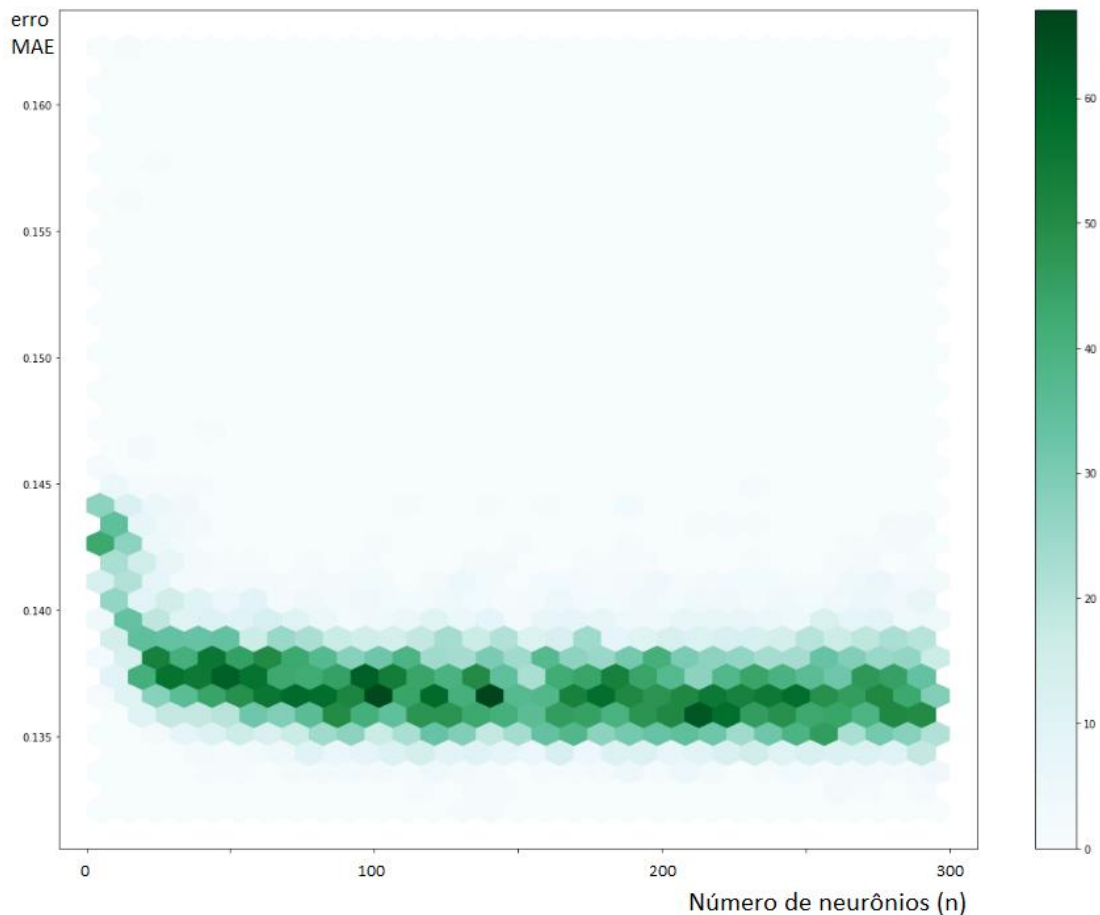


Fonte: os autores, 2022.

Na Figura 2, é possível observar que a curva da derivada do erro MAE apresenta um ponto de inflexão quando se aproxima de zero, indicando que o modelo atingiu uma estabilização no processo de treinamento. A partir desse ponto de inflexão, a curva da derivada apresenta uma constância no valor do erro MAE em torno de 0,137, sugerindo que aumentar ainda mais o número de neurônios não melhora significativamente a capacidade preditiva do modelo. Esse resultado indica que, para o conjunto de dados utilizado e as configurações dos hiperparâmetros selecionados, o modelo atingiu um limite de desempenho, o que sugere que pode ser uma boa escolha para a previsão do modelo.

A Figura 3 apresenta informações relevantes sobre as soluções geradas por Monte Carlo (retirado de 30 repetições) para a relação entre o MAE e o número de neurônios. Ao observar o gráfico, é possível notar que há uma tendência nas células mais escuras apontando para um patamar próximo ao MAE de 0,137, sugerindo que RNAs com número de neurônios entre 100 e 150 podem apresentar um bom equilíbrio entre complexidade e precisão de previsão. Essa informação pode ser útil para determinar a melhor configuração da RNA e otimizar o modelo, contribuindo para uma tomada de decisão mais assertiva.

É fundamental ressaltar que a escolha da melhor configuração da RNA é influenciada por diversos fatores, tais como a qualidade e tamanho dos dados disponíveis, o objetivo da previsão e o tempo disponível para o treinamento da rede. Ademais, é importante avaliar o desempenho do modelo em diferentes conjuntos de treinamento e teste, para garantir que o modelo seja capaz de generalizar para novos dados. Dessa forma, a seleção da melhor configuração da RNA deve ser cuidadosamente ponderada, levando em consideração todos esses fatores para garantir a precisão da previsão e a eficiência do modelo em relação ao tempo e recursos utilizados.

Figura 3 - *Hexaplot* do número de neurônios em função do erro MAE, 2022

Fonte: os autores, 2022.

Observa-se que, à medida que se aumenta o número de neurônios ( $n$ ), o erro MAE segue um padrão e tende a saturar. Isso significa que aumentar o número de neurônios acima de 150 não causa uma mudança significativa no erro, conforme indicado pela tendência da derivada se aproximar de zero, o que sugere um desperdício de recursos computacionais. Destaca-se que a análise do modelo de RNA exigiu um tempo considerável, levando pouco mais de 3 semanas. No entanto, essa análise cuidadosa foi fundamental para garantir a escolha adequada da configuração da RNA e evitar problemas de *overfitting* ou *underfitting*, que poderiam comprometer as estimativas.

Ao encontrar erros cada vez menores em uma RNA, é importante avaliar se a relação custo-benefício é satisfatória, considerando se a RNA está bem dimensionada e adequada. Nesse sentido, é interessante notar que não são necessários 150 neurônios para atingir uma RNA satisfatória, uma vez que 100 neurônios fornecem um erro MAE constante em torno de 13,7% e uma acurácia de 86,3%.


A maneira de avaliar o desempenho das redes neurais é através do exame da função de perda (FP), apresentada na Figura 4. Esta é uma medida que indica o quão bem a RNA está se ajustando aos dados durante o processo de treinamento, buscando reduzir o erro das previsões da RNA. É importante ressaltar que o gráfico da Figura 4 representa apenas uma aleatorização da RNA com um particionamento específico, e não uma média de diversas aplicações.

A taxa de aprendizagem é um parâmetro fundamental no treinamento de redes neurais e representa a correção aplicada a cada época para atualizar os pesos utilizados pela rede. No caso em questão, a função de perda foi otimizada pelo método NAdam e a taxa de aprendizagem utilizada foi de 0,01. Esse valor permitiu que a rede neural fosse treinada por um grande número de épocas, garantindo uma atualização constante dos pesos sem comprometer a taxa de aprendizagem.

É importante destacar que a escolha da taxa de aprendizagem depende das características do problema em questão e pode afetar significativamente o desempenho da rede neural. Uma taxa muito

alta poderia levar a instabilidade no treinamento, enquanto uma taxa muito baixa poderia resultar em um treinamento muito lento, ou, eventualmente, preso em um mínimo local.

Figura 4 - Evolução da função de perda em 65 épocas, 2022



Fonte: os autores, 2022.

A análise do comportamento da função de perda, tanto durante o treinamento quanto nos testes, fornece informações importantes sobre o desempenho da rede neural. No início do treinamento, observou-se um valor alto da função de perda, indicando uma baixa precisão nas previsões. No entanto, à medida que a rede neural ajustou os pesos e *bias* esta decresceu e estabilizou. No caso em questão, foi observado que após 30 épocas, a função de perda atingiu um patamar próximo a 0,137, valor que se manteve praticamente constante até o final do treinamento, mesmo que o número máximo de épocas tenha sido de 1500.

Para monitorar o desempenho da RNA, utilizou-se o coeficiente de correlação de Spearman, o qual foi empregado para avaliar a relação entre as previsões da RNA e os valores reais do conjunto de dados. O valor obtido para o coeficiente de correlação de Spearman (0.875,  $p < 1\%$ ) indica que a RNA foi capaz de reproduzir com precisão as tendências presentes nos dados.

Além disso, análises estatísticas e o cálculo do MAE foram empregados para avaliar o desempenho da RNA, que se mostrou satisfatório, permitindo seu uso para predição do conforto térmico. Com isso, a RNA poderá ser generalizada para outros conjuntos de dados de conforto térmico.

## CONCLUSÃO

O objetivo geral do estudo, que consistiu em desenvolver um modelo de RNA capaz de avaliar o conforto térmico com base nos dados da ASHRAE *Global Thermal Comfort*, foi alcançado. Além disso, os objetivos específicos traçados no início do estudo também foram alcançados com sucesso, o que incluiu a seleção dos parâmetros relevantes para a modelagem, ajuste dos hiperparâmetros de configuração da RNA, treinamento e teste da RNA, comparação dos resultados da RNA de percepção térmica observada e estimada, avaliação da acurácia da rede e sua generalização. Dessa forma, o estudo apresentou resultados consistentes e promissores para o desenvolvimento de modelos de RNA aplicados na avaliação do conforto térmico.

A generalização da RNA validada é uma ferramenta importante na prevenção de níveis de desconforto térmico humano em áreas urbanas. A partir de novos dados de entrada, a RNA é capaz de gerar saídas, que representam valores de conforto térmico, estimando o nível de conforto ou desconforto. Com isso, é possível planejar estratégias para melhorar a qualidade de vida das pessoas, permitindo uma análise precisa e em tempo real do conforto térmico, o que levaria a soluções mais eficazes e sustentáveis. Além disso, a validação da RNA para esse fim pode ser aplicada a outras áreas e problemas relacionados, aumentando seu potencial de uso e impacto.

## AGRADECIMENTOS

À Casa Civil do Governo do Estado de Mato Grosso e à CAPES pela bolsa de pesquisa.

## REFERÊNCIAS

- ASHRAE/ANSI, AMERICAN SOCIETY OF HEATING, REFRIGERATING and AIR-CONDITIONING ENGINEERS. **Standard 55-2017, Thermal Environment Condition for Human Occupancy**. Atlanta: ASHRAE Engineers, Inc. 2004-2010, Atlanta, atualizada em 2017.
- ASHRAE Global Thermal Comfort Database. Licença Open Database License. Disponível em: <https://datadryad.org/stash/dataset/doi:10.6078/D1F671>. Acesso em: 2 de março de 2023.
- BENZINGER, T. H. Heat regulation: homeostasis of central temperature in man. **Physiological reviews**, v. 49, n. 4, p. 671-759. 1969. <https://doi.org/10.1152/physrev.1969.49.4.671>
- CHAI, Q.; WANG, H.; ZHAI, Y.; YANG, L. Using Machine Learning Algorithms to Predict Occupants' Thermal Comfort in Naturally Ventilated Residential Buildings. **Journal Energy & Buildings**, n. 217, p. 109937, 2020. <https://doi.org/10.1016/j.enbuild.2020.109937>
- FANGER, P. O. **Thermal Comfort: Analysis and Applications in Environmental Engineering**. McGraw-Hill, New York, EUA, 1970.
- FAUSETT, L. V. **Fundamentals of neural networks: architectures, algorithms and applications**. Pearson Education India. 2006.
- FÖLDVÁRY, V. L.; CHEUNG, C. T.; ZHANG, H.; DE DEAR, R.; PARKINSON, T.; ARENS, E.; CHUN, C.; LUO, M.; BRAGER, G.; LI, P.; KAAM, S.; ADEBAMOWO, M.; ANDAMON, M.; BABICH, F.; BOUDEN, C.; BUKOVIANSKA, H.; CANDIDO, C.; CAO, B.; ZHOU, X. Development of the ASHRAE Global Thermal Comfort Database II. **Journal Building & Environment**, 2018.
- GÉRON, A. **Hands on Machine Learning with Scikit Learn Keras and Tensorflow - Concepts, Tools, and Techniques to Build Intelligent Systems**. Ed. O'Reilly Media, 2nd edition, Jupyter, Canada, 2019.
- GLOROT, X.; BORDES, A.; BENGIO, Y. **Deep Sparse Rectifier Neural Networks**. Appearing in Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS), Vol. 15, Fort Lauderdale, USA. 2011.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Ed. MIT Press. 2016.
- GRABE, V. Potential of artificial neural networks to predict thermal sensation votes. **Jörn. Applied Energy**, v. 161, p. 412-424, 2016. <https://doi.org/10.1016/j.apenergy.2015.10.061>
- KETTERER, C.; MATZARAKIS, A. Mapping the Physiologically Equivalent Temperature in urban areas using artificial neural network. **Landscape Urban Planning**, v. 150, p. 1-9. 2016. <https://doi.org/10.1016/j.landurbplan.2016.02.010>
- KOVÁCS, Z. L. **Redes Neurais Artificiais, Fundamentos e Aplicações**. 4ª edição revista. Editora Livraria da Física. PUC-SP. São Paulo, 2006.
- HAYKIN, S. **Redes Neurais Artificiais: Princípios e práticas**. 2ª edição, Editora Bookman, Porto Alegre, 2001.
- HÖPPE, P.; MAYER H. Planungsrelevante Bewertung der thermischen Komponente des Stadtklimas. **Landschaft Stadt**, n. 19, p. 22-29, 1987.



INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, ISO 10551. **Ergonomics of the thermal environment - Assessment of the influence of the thermal environment using subjective judgment scales.** Genebra, Switzerland, 1995.

LAMBERTS, R.; DUTRA, L.; PEREIRA, F.O.R. **Eficiência Energética na Arquitetura.** São Paulo PW Editores. 192 p. 1997.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. **Nature Publishing Group**, v. 521, n. 7553, p. 436, 2015. <https://doi.org/10.1038/nature14539>

MANDIC, D. P.; CHAMBERS, J. A. **Recurrent Neural Networks for Prediction.** Wiley. 2001. <https://doi.org/10.1002/047084535X>

MOUSTRIS, K.; TSIROS, L. X.; TSELIYOU, A.; NASTOS, P. Development Application of Artificial Neural Network Models to Estimate Values of a Complex Index of Human Thermal Comfort Associated with Urban Heat and Cold Island Patterns, Using Air Temperature Data from a Standard Weather Station. **International Journal of Biometeorology**, v. 62, p. 1265-1274, 2018. <https://doi.org/10.1007/s00484-018-1531-5>

NGUYEN, Q. H.; LY, H.; HO, L. S.; AL-ANSARI, N.; LE, H. V.; TRAN, V. Q.; PRAKASH, I.; PHAM, B. T. Influence of Data Splitting on Performance of Machine Learning Models in Prediction of Shear Strength of Soil. **Mathematical Problems in Engineering**, p. 4832864, 2021. <https://doi.org/10.1155/2021/4832864>

OKE, T. R. The energetic basis of the urban heat island. **Quart. Journal. Roy. Met. Soc.**, v. 108, p. 1-24, 1982. <https://doi.org/10.1002/qj.49710845502>

PATTERSON, J.; GIBSON, A. **Deep Learning: A Practitioner's Approach.** San Francisco, CA: O'Reilly Media, Inc., 538 p. 2017.

WANG, Z.; WANG, J.; HE, Y.; LIU, Y.; LIN, B.; HONG, T. **Dimension analysis of subjective thermal comfort metrics based on ASHRAE Global Thermal Comfort Database using machine learning.** Journal of Building Engineering, n. 29, p. 101120, 2020. <https://doi.org/10.1016/j.jobee.2019.101120>

YASSIN, M. A.; ALAZBA, A. A.; MATTAR, M. A. Artificial neural networks versus gene expression programming for estimating reference evapotranspiration in arid climate. **Agricultural Water Management**, v. 163, p. 110-124, 2016. <https://doi.org/10.1016/j.agwat.2015.09.009>

---

Recebido em: 25/10/2023

Aceito para publicação em: 13/12/2023