

## Aplicação de Redes Neurais Artificiais para previsão de distribuição de temperatura ao longo de um Trocador de Calor Solo-Ar

### Application of Artificial Neural Networks for predicting temperature distribution along a Earth-Air Heat Exchanger

Leonardo Bruno Foltran<sup>1</sup>, Hugo Valadares Siqueira<sup>2</sup>, Victor Vaurek Dimbarre<sup>3</sup>, Thiago Antonini Alves<sup>4</sup>, Gerson Henrique dos Santos<sup>5</sup>

#### RESUMO

No contexto brasileiro, cerca de metade do consumo de energia elétrica é proveniente de edificações, sendo grande parte desse consumo destinado à climatização. Nesse cenário, os trocadores de calor do tipo solo-ar tornam-se ferramentas úteis na redução do consumo elétrico em edificações. O Trocador de Calor Solo-Ar (TCSA) utiliza o solo como forma de aquecer ou resfriar o ar, dependendo das condições do ambiente local e climáticas. O TCSA utilizado neste estudo está localizado na Universidade Tecnológica Federal do Paraná (UTFPR), Campus Ponta Grossa, e é composto por dutos de Policloreto de Vinila (PVC) enterrados a uma profundidade de 1,5 metros e um ventilador para controlar o fluxo de ar. Quatro arquiteturas distintas de Redes Neurais Artificiais (RNAs) do tipo Perceptron Multicamadas (do inglês, MLP) foram utilizadas para obter a distribuição de temperatura ao longo do trocador de calor, a fim de prever seu desempenho quando sujeito a diferentes condições climáticas. Ao fim do estudo, foi possível concluir que as quatro estruturas de arquitetura MLP foram capazes de prever adequadamente as temperaturas dos termopares ao longo do trocador de calor.

**PALAVRAS-CHAVE:** Perceptron Multicamadas (MLP); Redes Neurais Artificiais (RNAs); Trocador de Calor Solo-Ar (TCSA).

#### ABSTRACT

In the Brazilian context, approximately half of the electrical energy consumption comes from buildings, with a significant portion of this consumption dedicated to air conditioning. In this scenario, ground-air heat exchangers become useful tools in reducing electrical consumption in buildings. The Earth-Air Heat Exchanger (EAHE) uses the ground to either heat or cool the air, depending on local environmental and climatic conditions. The EAHE used in this study is located at the Federal Technological University of Paraná (UTFPR), Ponta Grossa Campus, and consists of Polyvinyl Chloride (PVC) ducts buried at a depth of 1.5 meters and a fan to control the airflow. Four different architectures of Multilayer Perceptron (MLP) Artificial Neural Networks (ANNs) were employed to obtain the temperature distribution along the heat exchanger in order to predict its performance under different climatic conditions. At the end of the study, it was possible to conclude that all four MLP architecture structures were able to adequately predict the temperatures of the thermocouples along the heat exchanger.

**KEYWORDS:** Multilayer Perceptron (MLP); Artificial Neural Networks (ANNs); Earth-Air Heat Exchanger (EAHE).

<sup>1</sup> Bolsista do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. E-mail: leonardofoltran@alunos.utfpr.edu.br. ID Lattes: 0303470160030249.

<sup>2</sup> Docente no Departamento Acadêmico de Eletrônica (DAELE). Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. E-mail: hugosiqueira@utfpr.edu.br. ID Lattes: 6904980376005290.

<sup>3</sup> Acadêmico no Programa de Pós-Graduação em Engenharia Mecânica (PPGEM CP-PG). Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. E-mail: victordimbarre@alunos.utfpr.edu.br. ID Lattes: 2241512766412403.

<sup>4</sup> Docente no Departamento Acadêmico de Mecânica (DAMEC). Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. E-mail: antonini@utfpr.edu.br. ID Lattes: 0763708094190677.

<sup>5</sup> Docente no Departamento Acadêmico de Mecânica (DAMEC). Universidade Tecnológica Federal do Paraná, Ponta Grossa, Paraná, Brasil. E-mail: gsantos@utfpr.edu.br. ID Lattes: 0407596573800004.

## INTRODUÇÃO

No Brasil, metade da eletricidade consumida nas últimas décadas provém de edificações, o que cresceu proporcionalmente ao Produto Interno Bruto (PIB). Nesse contexto, a pesquisa sobre a eficiência energética de edificações tem crescido nos países em desenvolvimento, principalmente quando relacionada aos recursos finitos da natureza. Com o intuito de evoluir esse cenário, a redução da demanda energética necessária para o controle térmico em edificações provou ser muito promissora. Dessa forma, a literatura oferece várias alternativas (BRUGNERA *et al.*, 2019). Entre elas, uma das alternativas destacadas para reduzir o consumo de energia elétrica e melhorar as condições de conforto em edificações é o uso do solo como trocador de calor. Devido à sua alta inércia térmica, o solo pode manter uma temperatura quase constante em profundidades específicas, com pouca dependência das variações de temperatura que ocorrem na superfície (RAMÍREZ-DÁVILA *et al.*, 2014; HOLLMULER, LACHAL, 2014).

Além do alto tempo computacional necessário, analisar o desempenho do TCSA por meio de simulações numéricas pode ser complexo devido às interações não lineares entre várias variáveis, incluindo temperatura do ar, umidade, fluxo de ar e características do solo. Portanto, prever com precisão a distribuição de temperatura ao longo do tubo do trocador requer a modelagem adequada dessas interações complexas. Redes neurais artificiais (RNAs), como a arquitetura Perceptron Multicamadas (MLP), utilizada neste estudo, são uma escolha apropriada para realizar previsões, conforme destacado por Haykin (2009) em seu livro "Redes Neurais e Máquinas de Aprendizado". Ao treinar uma MLP usando dados operacionais históricos do trocador de calor, podemos estimar variações de temperatura ao longo do tubo, mesmo sob diferentes condições físicas iniciais, como taxas de fluxo de ar variáveis, temperaturas do solo e temperaturas do ar atmosférico. O uso desse modelo permite otimizar o funcionamento do trocador de calor, prever a distribuição de temperatura em todo o sistema e, conseqüentemente, tornar possível melhorar a eficiência energética e o desempenho.


Resultados de estudos que analisaram o desempenho de RNAs em trocadores de calor demonstram que redes neurais devidamente treinadas podem simular tanto as características gerais quanto específicas de um trocador de calor (TAN *et al.*, 2009). Por exemplo, em um artigo publicado por Kumar, Kaushik e Garg (2006), é relatado que para um TCSA, o uso de um algoritmo é adequado para calcular a temperatura do ar de saída, bem como o potencial de aquecimento e resfriamento do sistema. Além disso, o uso de RNAs para previsão de séries temporais é altamente apropriado, como evidenciado por Siqueira *et al.* (2020), onde a utilização de redes neurais de aprendizado extremo (do inglês, EML) demonstrou desempenho satisfatório para esse tipo de previsão.

Como observado na literatura, o uso de RNAs para analisar o desempenho de trocadores de calor, em geral, ainda precisa ser explorado, especialmente no que diz respeito ao TCSA. Portanto, neste trabalho, RNAs foram utilizadas para obter a distribuição de temperatura ao longo do trocador de calor e prever o desempenho desses trocadores de calor sujeitos a diferentes condições climáticas. Os modelos foram validados usando dados obtidos experimentalmente por meio de um protótipo construído na Universidade Tecnológica Federal do Paraná (UTFPR), Campus Ponta Grossa, Brasil.

## PROCEDIMENTO EXPERIMENTAL

A pesquisa experimental foi conduzida no Campus Ponta Grossa da Universidade Tecnológica Federal do Paraná - UTFPR. A Figura 1(a) mostra o design do trocador de calor e a Figura 1(b) a localização onde ele foi instalado, bem como suas respectivas dimensões.

Figura 1 - (a) Projeto, (b) Local de montagem



Fonte: Autoria própria (2023).

Montado com tubos de Policloreto de Vinila (PVC) de 100 mm de diâmetro dispostos em forma de serpentina e enterrados a uma profundidade de 1,5 metros da superfície, o TCSA possui tubos com comprimento médio de 5,15 metros e espaçamento de 0,50 metros entre eles, totalizando 50,65 metros de comprimento. Para esta pesquisa, foram analisadas três diferentes velocidades de fluxo de ar: 3 m/s, 5 m/s e 7,5 m/s, que foram medidas durante a operação de um ventilador radial usando um anemômetro digital. Foram instalados 14 termopares do tipo K ao longo do tubo para medição de temperatura. Os cinco primeiros estão posicionados nos primeiros 4,85 metros (primeira passagem), e os demais a cada 5,60 metros de tubo.

## PROCESSO DE DIVISÃO DOS DADOS E ESTRUTURAÇÃO DA REDE

Inicialmente, os dados foram divididos em conjuntos de entrada (com variáveis como velocidade do ar, temperatura do solo e temperatura do ar na entrada) e saída (com as temperaturas registradas por termopares ao longo do tubo). Antes do treinamento, os dados foram divididos em conjuntos de treinamento (80% do total de dados), validação (20% dos dados de treinamento) e teste. O conjunto de treinamento ajustou os pesos da rede, com a validação usando o método Early Stop para evitar o sobreajuste.

Para facilitar a busca na obtenção dos melhores resultados de previsão, é interessante explorar diferentes estruturas de redes MLP, já que algumas estruturas podem ser mais adequadas para capturar os padrões complexos e as relações presentes nos dados do que outras. Portanto, para esta pesquisa foram analisados quatro tipos distintos de estruturas para fins de comparação, conforme descrito na Tabela 1.

Tabela 1 - Estruturas de MLPs utilizadas no treinamento

Número do Modelo	Arquitetura	Dados de entrada	Camadas ocultas	Número de nós (por camada oculta)	Função de ativação (por camada oculta)	Algoritmo de otimização	Dados de saída	Métrica de validação
1	MLP	Fluxo de ar; temperatura do solo; temperatura atmosférica.	2	20; 20	Sigmoide; Sigmoide	Adam	12 sensores	EQM
2			2	20; 20	Tanh; Tanh		12 sensores	
3			1	15	Sigmoide		1 sensor	
4			1	15	Tanh		1 sensor	

Fonte: Autoria própria (2023).

Para os modelos 1 e 2, as redes possuem 12 saídas, uma para cada termopar ao longo do tubo do trocador de calor. Já os modelos 3 e 4 têm apenas 1 saída, correspondente a um único termopar, ou seja, a rede foi treinada 12 vezes, uma vez para cada sensor. Além disso, para otimizar a busca pelos pesos ideais, optou-se pelo algoritmo de otimização Adam. Para efeitos de comparação, as diferenças entre os modelos 1 e 2, bem como entre 3 e 4, derivam das funções de ativação utilizadas: modelos 1 e 3 usaram a função sigmoide, enquanto modelos 2 e 4 adotaram a função tangente hiperbólica.

Durante a fase de validação, calculou-se a perda com base no erro quadrático médio (EQM). Além do EQM, utilizou-se também o erro médio absoluto (EMA) e o erro máximo de temperatura (EMT) para avaliar o desempenho das redes.

É relevante destacar que cada um dos quatro modelos MLP foi treinado independentemente 30 vezes, permitindo que os modelos explorassem diversas trajetórias de aprendizado e evitassem ficar presos em mínimos locais.

## RESULTADOS

Com base nos dados coletados dos sensores de termopar e do anemômetro digital, durante vários períodos de 2021 a 2023, com coleta de dados a cada hora, resultando em um total de 19.470 registros de dados, os resultados de treinamento para os quatro modelos de MLP podem ser observados na Tabela 2.

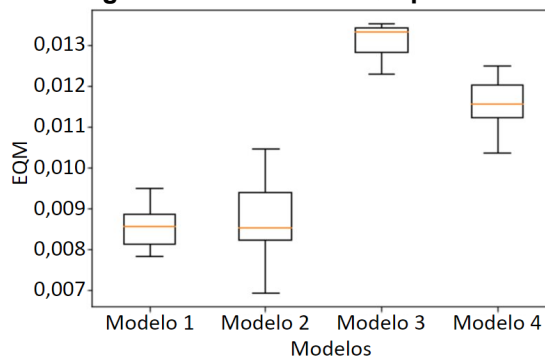
Tabela 2 - Comparação do EQM, EMA e EMT para todos os modelos de MLP

Número do Modelo	EQM	EMA	EMT (°C)
1	0.0078	0.0634	0.67
2	0.0063	0.0568	0.62
3	0.0115	0.0774	0.70
4	0.0103	0.0726	0.67

Fonte: Autoria própria (2023).


Para melhor comparar os resultados do teste, o gráfico de caixa (Figura 2) ilustra a distribuição do EQM de todos os treinamentos realizados para cada modelo. Além disso, os gráficos de dispersão (Figura 3) comparam os valores previstos com os valores reais para o conjunto de teste, com base na MLP de melhor desempenho para cada modelo.

Figura 2 - Diagrama de caixa do EQM para cada modelo



Fonte: Autoria própria (2023).

Figura 3 - Comparação dos valores previstos e reais de temperatura para MLPs: (a) Modelo 1, (b) Modelo 2, (c) Modelo 3, (d) Modelo 4



Fonte: Autoria própria (2023).

Com base nos dados da Tabela 2, pode-se afirmar que o melhor modelo (entre as estruturas listadas na Tabela 1) foi o Modelo 2, uma vez que apresentou os valores mais baixos de EQM, EMA e EMT. No entanto, é importante notar que o Modelo 2 também demonstra uma maior variação em comparação com o Modelo 1, como evidenciado na Figura 2. Analisando o diagrama de caixa, os Modelos 3 e 4 apresentaram baixa variação, mas tiveram valores elevados de EQM em comparação com os dois primeiros modelos.

No entanto, fica evidente que todos os modelos alcançaram previsões de temperatura adequadas, conforme demonstrado na Figura 3, onde os gráficos de dispersão mostram a proximidade das previsões com os valores reais.

Ao analisar os resultados, algumas hipóteses podem ser levantadas, como a relação entre o número de neurônios e camadas ocultas com os resultados obtidos. Observa-se que, de forma geral, o aumento do número de camadas ocultas nos Modelos 3 e 4, ou a realização de uma busca mais eficaz pelo número ideal de nós por camada em todos os modelos, poderiam levar a resultados mais satisfatórios.

## CONCLUSÕES

Os resultados das MLPs, de forma geral, atenderam às expectativas em relação às previsões de temperatura e ao desempenho do modelo, com o Modelo 2 obtendo o melhor resultado, mesmo que tenha apresentado maior variação.

A função de ativação tangente hiperbólica, apesar de exibir maior variação, demonstrou um melhor EQM em comparação com a função sigmoide. Isso sugere que a tangente hiperbólica é mais adequada para este tipo de estudo.

Para estudos futuros, outros tipos de RNAs podem ser explorados, como redes neurais recorrentes (RNNs) ou máquinas de aprendizado extremo (ELMs), que podem

aprimorar ainda mais a precisão e o desempenho das previsões para o problema específico em questão.

## Agradecimentos

Primeiramente, gostaria de agradecer à UTFPR pelo suporte e pelos recursos disponibilizados ao longo deste trabalho. Quero estender meus sinceros agradecimentos ao meu orientador, Prof. Dr. Gerson Henrique dos Santos, pela valiosa oportunidade, orientação e ensinamentos que me foram transmitidos. Também gostaria de reconhecer o Prof. Dr. Hugo Valadares Siqueira pela sua constante ajuda e conhecimentos passados sobre redes neurais artificiais. Por fim, agradeço a instituição CNPq pela viabilização de recursos em formato de bolsa que tornou esta pesquisa possível.

## Conflito de interesse

Não há conflito de interesse.

## REFERÊNCIAS

BRUGNERA, R. R.; MATEUS, R.; ROSSIGNOLO, J. A.; CHVATAL, K. M. S. Escritórios de planta livre: o impacto de diferentes soluções de fachada na eficiência energética. **Ambiente Construído**, Porto Alegre, v. 19, n. 3, p. 295-315, jul./set. 2019.

HAYKIN, S. **Neural Networks and Learning Machines**. 3rd edition. Pearson Education, Bengaluru, India, 2009.

HOLLMULLER, P.; LACHAL, B. Air-soil heat exchangers for heating and cooling of buildings: Design guidelines, potentials and constraints, system integration and global energy balance. **Applied Energy**, Vol. 119, p. 476-487, 2014.

KUMAR, R., KAUSHIK, S. C., GARG, S. N. Heating and cooling potential of an earth-to-air heat exchanger using artificial neural network. **Renewable Energy**, Vol. 31, Issue 8, pp. 1139–1155, 2006.

RAMÍREZ-DÁVILA, L., XAMÁN, J., ARCE, J., ÁLVAREZ, G., HERNÁNDEZ-PÉREZ, I. Numerical study of earth-to-air heat exchanger for three different climates. **Energy and Buildings**, Vol. 76, p. 238-248, 2014.

SIQUEIRA, H., MACEDO, M., TADANO, Y. DE S., ALVES, T. A., STEVAN, S. L., OLIVEIRA, D. S., MARINHO, M. H. N., NETO, P. S. G. M., OLIVEIRA, J. F. L., LUNA, I., FILHO, M. A. L., SARUBBO, L. A., CONVERTI, A. Selection of Temporal Lags for Predicting Riverflow Series from Hydroelectric Plants Using Variable Selection Methods. **Energies**, 13(16), 4236, 2020.

TAN, C. K., WARD, J., WILCOX, S. J., PAYNE, R. Artificial neural network modeling of the thermal performance of a compact heat exchanger. **Applied Thermal Engineering**, Vol. 29, Issue 17-18, pp. 3609–3617, 2009.