

Emprego de Redes Neurais Artificiais na Previsão do Desempenho Térmico de Tubos de Calor

Thomas Siqueira Pereira
Universidade Tecnológica
Federal do Paraná (UTFPR)

Ponta Grossa, Brasil
thomaspereira@alunos.utfpr.edu.br

Hugo Valadares Siqueira
Universidade Tecnológica
Federal do Paraná (UTFPR)

Ponta Grossa, Brasil
hugosiqueira@utfpr.edu.br

Yara de Souza Tadano
Universidade Tecnológica
Federal do Paraná (UTFPR)

Ponta Grossa, Brasil
yaratadano@utfpr.edu.br

Thiago Antonini Alves
Universidade Tecnológica
Federal do Paraná (UTFPR)
Ponta Grossa, Brasil
antonini@utfpr.edu.br

Resumo—Tubos de calor são dispositivos térmicos passivos amplamente utilizados em aplicações que exigem elevada eficiência na transferência de calor, como sistemas eletroeletrônicos, aeroespaciais e de energia renovável. A modelagem analítica do comportamento térmico desses dispositivos é desafiadora, pois envolve fenômenos conjugados de convecção e mudança de fase, frequentemente exigindo simplificações que comprometem a precisão dos resultados. Diante dessa limitação, este trabalho investiga o emprego de técnicas de inteligência computacional, com ênfase em Redes Neurais Artificiais (RNA), como alternativa eficiente para a previsão do desempenho térmico de tubos de calor com diferentes estruturas capilares. Foram desenvolvidas e avaliadas três arquiteturas de RNA: *Perceptron* de Múltiplas Camadas (MLP), Rede com Função de Base Radial (RBF) e Máquina de Aprendizagem Extremo (ELM). As redes neurais foram treinadas com dados experimentais obtidos em laboratório, abrangendo variações de inclinação, razão de preenchimento, potência dissipada e tipo de estrutura capilar. O desempenho dos modelos foi avaliado pelas métricas MAE, RMSE e MAPE. Os resultados indicam que a rede MLP apresentou o melhor desempenho preditivo, com MAPE médio de 13,93%, demonstrando maior robustez e capacidade de generalização frente às demais arquiteturas. Esse estudo reforça a viabilidade da aplicação de métodos de aprendizado de máquina em engenharia térmica, contribuindo para redução do tempo de desenvolvimento e o aumento da confiabilidade das previsões em sistemas com múltiplas variáveis operacionais.

Palavras-chave—tubos de calor, inteligência computacional, Redes Neurais Artificiais, transferência de calor, aprendizado de máquina

Abstract—Heat pipes are passive thermal devices widely used in applications that demand high heat transfer efficiency, such as electronic, aerospace, and renewable energy systems. Analytical modeling of the thermal behavior of these devices is challenging, as it involves coupled phenomena of convection and phase change, often requiring simplifications that compromise the accuracy of the results. To address this limitation, this study investigates the use of computational intelligence techniques, with an emphasis on Artificial Neural Networks (ANN), as an efficient alternative for predicting the thermal performance of heat pipes with different capillary structures. Three ANN architectures were developed and evaluated: Multilayer Perceptron (MLP), Radial Basis Function (RBF), and Extreme Learning Machine (ELM). The neural networks were trained with experimental data obtained in the laboratory, considering variations in slope, filling ratio, heat load, and capillary structure type. Model performance was assessed using the

MAE, RMSE, and MAPE metrics. The results indicate that the MLP network achieved the best predictive performance, with an average MAPE of 13.93%, demonstrating greater robustness and generalization capability compared to the other architectures. This study reinforces the feasibility of applying machine learning methods in thermal engineering, contributing to the reduction of development time and the increase in reliability of predictions in systems with multiple operational variables.

Keywords—heat pipes, computational intelligence, Artificial Neural Networks, heat transfer, machine learning

I. INTRODUÇÃO

Os tubos de calor são dispositivos térmicos passivos amplamente utilizados em aplicações que exigem elevada eficiência na transferência de calor, como sistemas eletroeletrônicos, aeroespaciais e fontes de energia renovável [1].

O princípio de funcionamento de um tubo de calor está ilustrado na Fig. 1. Nesse dispositivo, o calor fornecido ao evaporador provoca a vaporização do fluido de trabalho, que se desloca em direção ao condensador devido ao gradiente de pressão. No condensador, o vapor libera energia na forma de calor ao ambiente e retorna à fase líquida. A estrutura capilar conduz esse líquido de volta ao evaporador, fechando o ciclo de operação. Esse processo permite elevada eficiência térmica com transporte passivo de energia térmica [2].




Fig. 1 Representação esquemática do princípio de funcionamento de um tubo de calor.

O desempenho térmico dos tubos de calor depende de fatores como a geometria da estrutura capilar, tipo de fluido de trabalho, razão de preenchimento e condições operacionais [3]. Modelos analíticos convencionais, embora úteis, frequentemente exigem simplificações significativas para tratar os fenômenos conjugados de convecção e mudança de fase, o que compromete sua precisão e generalização [4].

Como alternativa, técnicas de inteligência computacional têm sido cada vez mais empregadas para modelagem de sistemas térmicos complexos. Em especial, Redes Neurais Artificiais (RNA) demonstram alta capacidade de aprendizado e generalização em problemas com múltiplas variáveis não lineares [5].

As Redes Neurais Artificiais são modelos computacionais desenvolvidos com base no sistema nervoso dos organismos superiores, como os animais, com objetivo de prever diversos comportamentos de problemas complexos sem a necessidade de conhecimento profundo acerca da teoria por trás desse. O funcionamento das RNA se baseia em utilizar dados experimentais obtidos anteriormente. Portanto, é possível “ensinar” a rede neural sobre o comportamento de problemas complexos [6]. Esses algoritmos são formados pela conexão de pequenos módulos, usualmente chamados neurônios, distribuídos em diferentes camadas, como é representado na Fig. 2. Esses neurônios simulam o comportamento de neurônios orgânicos, recebendo dados de entrada e realizando operações matemáticas simples para obter novos valores que serão transmitidos às camadas seguintes até, finalmente, obter resultados da camada de saída.




Fig. 2 Representação esquemática de uma Rede Neural Artificial.

A literatura carece de estudos que comparem, de forma sistemática e com base em dados experimentais controlados, o desempenho de diferentes arquiteturas de RNA aplicadas à previsão do desempenho térmico de tubos de calor com diferentes estruturas capilares.

Neste contexto, no presente trabalho são analisadas três arquiteturas de RNA, *Perceptron* de Múltiplas Camadas (do inglês, *Multilayer Perceptron* – MLP), Rede com Função de Base Radial (do inglês, *Radial Basis Function* – RBF) e Máquina de Aprendizado Extremo (do inglês, *Extreme Learning Machine* – ELM), na previsão do desempenho térmico de tubos de calor com diferentes estruturas internas: ranhuras axiais, pó sinterizado e tela metálica. As redes neurais foram treinadas com dados experimentais e avaliadas pelas métricas MAE, RMSE e MAPE.

II. METODOLOGIA

A. Banco de Dados (Parte Experimental)

O conjunto de dados utilizado nesse trabalho foi obtido por meio de experimentos realizados no Laboratório de Controle Térmico (LabCT) vinculado ao Programa de Pós-Graduação *Multicampi* em Engenharia Mecânica (PPGEM) da Universidade Tecnológica Federal do Paraná (UTFPR/Ponta Grossa).

As etapas do preparo, limpeza, montagem, teste de estanqueidade, evacuação e preenchimento com fluido de trabalho do tubo de calor foram realizadas de acordo com as instruções existentes em [7]. Os tubos de calor utilizados foram confeccionados em cobre, com diâmetro externo de 9,45mm, com diâmetro interno de 7,75mm e com comprimento total de 200mm, sendo 80mm de evaporador, 20mm de seção adiabática e 100mm de condensador. Foram testadas três configurações distintas de estrutura capilar para os tubos de calor: ranhuras axiais [8], sinterização de pó de bronze [9] e tela metálica de bronze fosforoso [10]. O fluido de trabalho utilizado em todos os casos foi água destilada.

Essa etapa experimental possibilitou a criação de uma base de dados consistente, essencial para o treinamento e a validação das RNA. A seguir, são detalhadas as configurações específicas de cada estrutura capilar investigada, bem como o aparato experimental empregado para a coleta dos dados.

Nishida *et al.* [8] apresentaram dados referentes a tubos de calor com estrutura capilar de microranhuras axiais fabricadas por eletroerosão a fio diretamente no tubo de cobre. Foram obtidos dados para três variações diferentes da estrutura capilar, variando-se a profundidade e o espaçamento entre as microranhuras. Para a base de dados, foram utilizados os resultados obtidos com microranhuras de espessura de 0,035mm e profundidade de 0,030mm (Fig. 3).




Fig. 3 Microranhuras axiais fabricadas por eletroerosão a fio.

Krambeck *et al.* [9] utilizaram estruturas capilares de pó de cobre sinterizado em tubos de calor. A estrutura capilar sinterizada foi fabricada a partir de pó de cobre obtido por atomização a gás. O material foi então sinterizado, produzindo estruturas com três diferentes diâmetros internos. Para a base de dados desse trabalho, foram utilizados os dados obtidos para a estrutura com diâmetro interno de 0,875mm (Fig. 4).




Fig. 4 Sinterização de pó de cobre.

Krambeck [10] avaliou experimentalmente tubos de calor com telas metálicas de bronze fosforoso utilizando três diferentes tipos de malha. Para a base de dados desse trabalho, foram utilizados os resultados obtidos na avaliação de tubos de calor com uma única camada de tela metálica de *mesh* #100 (Fig. 5).




Fig. 5 Tela metálica (*mesh* #100).

Para a execução dos testes, o aparato experimental utilizado, mostrado na Fig. 6, foi composto por um ventilador para realizar o arrefecimento do dispositivo, uma fonte de alimentação *Keysight*TM U8002A, uma unidade de aquisição, comutação e registro de dados *Keysight*TM 34970A com um multiplexador de 20 canais *Keysight*TM 34901A, um computador portátil *Dell*TM, um *nobreak APC*TM e um suporte universal com garras. Para determinação da velocidade do ar, foi utilizado um termoanemômetro Digital Portátil *Itan*TM 720. A temperatura do ar durante os testes experimentais foi de $20,0^{\circ}\text{C} \pm 2,0^{\circ}\text{C}$, mantida com o auxílio de uma unidade de condicionamento de ar *Carrier*TM de 36.000BTU/h.



Fig. 6 Aparato experimental.

Os experimentos foram conduzidos com variações nos seguintes parâmetros operacionais: ângulo de inclinação do tubo de calor em relação à horizontal (0° , 45° e 90°); razão de preenchimento (40%, 60%, 80%, 100% e 120%); e potência dissipada no evaporador (de 5W a 50W em incrementos de 5W).

O parâmetro escolhido para avaliação do desempenho térmico dos tubos de calor foi a resistência térmica (R_{th}), que pode ser expressa por:

$$R_{th} = \frac{(T_{evap} - T_{cond})}{q_{in}}, \quad (1)$$

sendo que, o T_{evap} é a temperatura média do evaporador, T_{cond} é a temperatura média do condensador e q_{in} é a potência dissipada no evaporador do tubo de calor.

Foram obtidas, ao todo, 108 combinações experimentais distintas, distribuídas uniformemente entre as três estruturas capilares investigadas para os tubos de calor. As variáveis de entrada utilizadas para o treinamento das redes neurais foram: tipo de estrutura capilar; inclinação de operação; razão de preenchimento; e potência dissipada. A variável de saída foi a resistência térmica [$^{\circ}\text{C}/\text{W}$].

B. Redes Neurais Artificiais

O objetivo da modelagem computacional foi avaliar a capacidade preditiva de diferentes arquiteturas de Redes Neurais Artificiais (RNA) para estimar a resistência térmica a partir dos tubos de calor com diferentes estruturas capilares e de suas condições operacionais.

Como mencionado anteriormente, as arquiteturas de RNA investigadas foram: *Perceptron* de Múltiplas Camadas (MLP), Rede com Função de Base Radial (RBF) e Máquina de Aprendizado Extremo (ELM). Cada uma das redes neurais foi construída utilizando a linguagem de programação *Python*[®], sem a utilização de bibliotecas prontas, com objetivo de aumentar o entendimento do funcionamento de cada rede neural e o controle sobre os parâmetros usados.

Os dados experimentais foram usados para o treinamento de cada uma das RNA utilizadas. O treinamento tem métodos diferentes para cada uma das redes neurais utilizadas. A rede RBF conta com etapas de treinamento diferentes para as camadas ocultas e para a camada de saída. A camada oculta foi treinada utilizando o Algoritmo *k-means*, enquanto que a camada de saída foi treinada utilizando o Algoritmo *Backpropagation*. A rede MLP foi treinada seguindo a metodologia apresentada em [6] utilizando o Algoritmo *Backpropagation* para ambas as camadas. O treinamento da rede ELM utilizou o método encontrado em [11].

No treinamento de cada RNA existem parâmetros variáveis que são usualmente encontrados testando uma grande variedade de possibilidades, como por exemplo o número de neurônios utilizados na camada oculta. Essas propriedades foram avaliadas durante o treinamento em uma etapa inicial que utilizava menos épocas de treinamento para a busca desses parâmetros. Foram selecionadas as combinações de parâmetros que geraram resultados com os menores RMSE em relação aos dados de teste. Alguns dos parâmetros importantes utilizados durante o treinamento de RNA foram: número de camadas ocultas, número de neurônio em cada camada oculta e as funções de ativação utilizadas. Para cada uma das redes neurais utilizadas, os parâmetros utilizados estão listados na Tabela I. Cada RNA foi treinada diversas vezes e o valor médio entre todos os valores obtidos foi o resultado a ser avaliado. Uma vez encontrada a melhor combinação de parâmetros para esse caso a rede neural foi treinada novamente utilizando um número maior de épocas para a obtenção dos resultados finais. O número de épocas utilizado foi de 1000 para a fase inicial de treinamento e de 10000 para a fase final.

TABELA I. PARÂMETROS USADOS NO TREINAMENTO DE CADA RNA.

Modelo	Número de neurônios	Número de Camadas Ocultas	Função de Ativação	
			Oculto	Saída
MLP	3 – 200	1	Logística	Linear
RBF	3 – 200	1	Gaussiana	Linear
ELM	3 – 200	1	Logística	Linear

Os dados foram normalizados entre 0 e 1 e divididos aleatoriamente em três subconjuntos: 70% para treinamento, 15% para validação cruzada e 15% para teste final. A divisão foi mantida constante entre as arquiteturas para permitir comparação justa.

A avaliação de desempenho foi realizada com base em três métricas amplamente utilizadas: Erro Absoluto Médio (do inglês, *Mean Absolute Error* – MAE), Raiz Quadrada do Erro Quadrático Médio (do inglês, *Root Mean Squared Error* – RMSE) e Erro Percentual Absoluto Médio (do inglês, *Mean Absolute Percentage Error* – MAPE). Cada modelo foi executado 30 vezes, com diferentes inicializações de pesos (MLP e RBF) ou diferentes conjuntos de neurônios aleatórios (ELM), visando reduzir a influência de variações estocásticas e obter resultados estatisticamente robustos.

III. RESULTADOS E DISCUSSÃO

Na Tabela II são apresentados os resultados obtidos para as métricas MAE, RMSE e MAPE para cada arquitetura de RNA bem como o valor *NN* do número de neurônios na camada oculta. Esses valores foram obtidos a partir da média dos erros entre 30 testes independentes.

TABELA II. ERROS ENCONTRADOS PARA CADA RNA

Modelo	NN	MAE	RMSE	MAPE [%]
MLP	15	0,241	0,409	13,96
RBF	102	0,669	0,882	67,03
ELM	84	0,285	0,384	25,74

Esses resultados apresentados mostram que as redes MLP e ELM foram capazes de generalizar melhor o problema, gerando resultados com erros consistentes entre testes e dentro dos patamares esperados. É possível notar também que a rede MLP apresentou melhores resultados em relação aos erros MAPE e MAE para esse problema. O MAPE encontrado para a rede MLP foi cerca de 45% menor que aquele apresentado pela rede ELM. Enquanto que o MAE, foi cerca de 15% menor. O menor RMSE foi encontrado para a rede ELM com um resultado aproximadamente 6% menor que o resultado para a rede MLP. A rede RBF demonstrou maiores erros durante os testes, com resultados bastante inferiores aos mostrados pelas outras redes neurais. As Figs. 7, 8 e 9 são os diagramas de caixa (*boxplot*) do MAPE, RMSE e MAE, respectivamente, calculados para as 30 simulações realizadas para cada rede neural utilizada.




Fig. 7 Diagrama de caixa para MAPE das 30 simulações por arquitetura.




Fig. 8 Diagrama de caixa para MAE das 30 simulações por arquitetura.




Fig. 9 Diagrama de caixa para RMSE das 30 simulações por arquitetura.

A Fig. 10 mostra a comparação entre as resistências térmicas dos tubos de calor com diferentes estruturas capilares obtidas experimentalmente e os valores obtidos utilizando as diferentes arquiteturas de RNA. Em relação às redes ELM e MLP, foi possível visualizar que, além de gerarem bons valores médios de erro, mostrados nos diagramas de caixa (*boxplot*), as redes neurais geraram também resultados consistentes para os valores individuais obtidos. Pode ser analisado que a maioria dos resultados obtidos se encontram dentro da faixa de 30% de erro, além de se concentrarem próximos à linha central, que representa os valores ótimos. Ambas as redes neurais tiveram comportamentos semelhantes nesse caso, apesar da rede ELM apresentar alguns pontos discrepantes (*outliers*). A rede RBF, mais uma vez, apresentou resultados piores que as outras redes neurais com valores bem distantes dos valores ótimos.

A Fig. 11 apresenta os mesmos resultados da Fig. 10, porém, limitado à região com resistências térmicas menores que 1,2K/W, uma vez que cerca de 50% das amostras estão concentradas abaixo desse valor. É possível perceber que nessa região os valores obtidos utilizando a rede RBF mostraram as maiores divergências em porcentagem, com os experimentais. Os valores obtidos com a rede ELM também apresentaram muitos casos com erros maiores que 30% enquanto a rede MLP foi a única que apresenta resultados consistentemente dentro da faixa de erro esperada.




Fig. 10 Comparação entre os valores experimentais e calculados por cada RNA.




Fig. 11 Comparação entre os valores experimentais e calculados por cada RNA para resistências térmicas menores do que 1,2K/W.

Essas análises reforçam que apesar de todas as redes neurais tenham sido capazes de capturar tendências globais, a rede MLP é a mais confiável em termos de precisão e robustez, sendo a mais indicada para aplicações reais em ambientes com múltiplas variáveis de influência térmica.

Apesar dos resultados promissores obtidos, esse estudo apresenta algumas limitações que devem ser consideradas. Primeiramente, a base de dados utilizada, embora abrangente, foi restrita a 108 combinações experimentais, o que pode limitar a capacidade de generalização dos modelos em cenários mais amplos. Além disso, foram investigadas apenas três configurações de estruturas capilares e um único fluido de trabalho (água destilada), restringindo a aplicabilidade dos resultados a outras condições operacionais ou fluidos.

Embora os modelos analíticos clássicos sejam amplamente utilizados na literatura para a previsão do desempenho de tubos de calor, sua aplicação demanda simplificações significativas dos fenômenos de convecção e mudança de fase, o que frequentemente compromete sua precisão e capacidade de generalização. Em contrapartida, as Redes Neurais Artificiais permitem capturar relações não lineares complexas a partir de dados experimentais, fornecendo previsões mais precisas em cenários multivariados. Por outro lado, o emprego de RNA exige a disponibilidade de bases de dados experimentais robustas, além de maior custo computacional no processo de treinamento. Portanto, a adoção de técnicas de inteligência computacional deve ser vista como complementar aos modelos analíticos, oferecendo maior acurácia em troca de um investimento maior em coleta de dados e processamento.

IV. CONCLUSÃO

Esse trabalho demonstrou a empregabilidade de técnicas de inteligência computacional, em especial Redes Neurais Artificiais (RNA), na previsão do desempenho térmico de tubos de calor com diferentes estruturas capilares. Foram comparadas três arquiteturas clássicas, *Perceptron* de Múltiplas Camadas (do inglês, *Multilayer Perceptron* – MLP), Rede com Função de Base Radial (do inglês, *Radial Basis Function* – RBF) e Máquina de Aprendizado Extremo (do inglês, *Extreme Learning Machine* – ELM), treinadas com dados experimentais englobando múltiplas condições operacionais. Os resultados evidenciaram que a rede MLP apresentou o melhor desempenho global, combinando menor erro médio, menor dispersão e maior estabilidade estatística entre as execuções. A rede ELM, embora computacionalmente eficiente, mostrou-se sensível à aleatoriedade de sua estrutura interna. A rede RBF, por sua vez, apresentou a maior variação e os maiores erros percentuais, com dificuldades de generalização. A abordagem baseada em RNA mostrou-se eficaz na representação de comportamentos térmicos complexos, oferecendo uma alternativa promissora para aplicações de projeto assistido por dados em engenharia térmica. A utilização dessas técnicas pode contribuir para a redução do tempo de desenvolvimento, melhoria da acurácia preditiva e aumento da confiabilidade em sistemas com múltiplas variáveis de influência.

AGRADECIMENTOS

Agradecimentos são prestados à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsas de mestrado ao acadêmico *Thomas Siqueira Pereira*, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsas de produtividade em pesquisa aos Profs. *Hugo Valadares Siqueira* e *Thiago Antonini Alves* e pelo apoio financeiro no desenvolvimento de Projeto Universal e à Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná pelo apoio financeiro (Convênio nº 129/2022) e pela bolsa de produtividade à profa. *Yara de Souza Tadano*. Agradecimentos também são externados à Pró-Reitoria de Pesquisa e Pós-Graduação (PROPPG) da UTFPR, à Diretoria de Pesquisa e Pós-Graduação (DIRPPG), ao Programa de Pós-Graduação *Multicampi* (Mestrado) em Engenharia Mecânica (PPGEM-CP/PG) e ao Departamento Acadêmico de Mecânica (DAMEC) da Universidade Tecnológica Federal do Paraná, UTFPR/Campus Ponta Grossa.

REFERÊNCIAS

- [1] B. Zohuri, *Heat Pipe Design and Technology: Modern Applications for Practical Thermal Management*, 2nd ed. Springer Nature: Cham, CHE, 2016.
- [2] D.A. Reay, P.A. Kew, and R.J. McGlen, *Heat Pipe: Theory, Design and Applications*, 6th ed. Butterworth-Heinemann: Oxford, UK, 2014.
- [3] M.B.H. Mantelli, *Thermosyphons and Heat pipes: Theory and Applications*, 1st ed. Springer Nature: Cham, CHE, 2021.
- [4] T. S. Pereira, *Aplicação de Redes Neurais Artificiais na predição do desempenho térmico de tubos de calor e termossifões*. Dissertação de Mestrado em Engenharia Mecânica, Universidade Tecnológica Federal do Paraná, Ponta Grossa, Brasil, 2023.
- [5] P.L.O. Machado, T.S. Pereira, M.T. Guerreiro, F.M. Biglia, P.H.D. Santos, Y.S. Tadano, H.V. Siqueira, and T. Antonini Alves, “Estimating thermal performance of thermosyphons by Artificial Neural Networks”, *Alexandria Engineering Journal*, vol. 79, pp. 93–104, 2023.
- [6] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Pearson Prentice Hall: New York, USA, 2009.
- [7] T. Antonini Alves, L. Krambeck, and P.H.D. Santos, “Heat pipe and thermosyphon for thermal management of thermoelectric cooling” in *Bringing Thermoelectricity Into Reality*, vol. I, P. Aranguren, Ed. London, GBR: IntechOpen, 2018, pp. 353–374.
- [8] F.B. Nishida, L. Krambeck, P.H.D. Santos, and T. Antonini Alves, “Experimental investigation of heat pipe thermal performance with microgrooves fabricated by wire electrical discharge machining (wire-EDM)”, *Thermal Science*, vol. 24, pp. 701–711, 2020.
- [9] L. Krambeck, G.A. Bartmeyer, D.O. Souza, D. Fusão, P.H.D. Santos, and T. Antonini Alves, “Selecting sintered capillary structure for heat pipes based on experimental thermal performance”, *Acta Scientiarum. Technology*, vol. 44, 57099, 2022.
- [10] L. Krambeck, *Investigação experimental do desempenho térmico de telas metálicas em tubos de calor*. Trabalho de Conclusão de Curso em Engenharia Mecânica, Universidade Tecnológica Federal do Paraná, Ponta Grossa, Brasil, 2016.
- [11] G.B. Huang, Q.Y. Zhu, and C.K. Siew, “Extreme Learning Machine: Theory and applications”, *Neurocomputing*, vol. 70, pp. 489–501, 2006.