

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**THOMAS SIQUEIRA PEREIRA**

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DO  
DESEMPENHO TÉRMICO DE TUBOS DE CALOR E TERMOSSIFÕES**

**PONTA GROSSA**

**2023**

**THOMAS SIQUEIRA PEREIRA**

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DO  
DESEMPENHO TÉRMICO DE TUBOS DE CALOR E TERMOSSIFÕES**

**Application of artificial neural networks in predicting the thermal performance  
of heat pipes and thermosyphons**

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia Mecânica, do programa de Pós Graduação em Engenharia Mecânica da Universidade Tecnológica Federal do Paraná (UTFPR).

Área de Concentração: Térmicas e Fluidos

Orientadora: Profa. Dra. *Yara de Souza Tadano*

Coorientador: Prof. Dr. *Thiago Antonini Alves*

**PONTA GROSSA**

**2023**



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)

Esta licença permite *download* e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



THOMAS SIQUEIRA PEREIRA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DO DESEMPENHO TÉRMICO DE TUBOS DE CALOR E TERMOSSIFÕES**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Mecânica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Térmica E Fluidos.

Data de aprovação: 30 de agosto de 2023

Dra. Yara De Souza Tadano, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Gerson Henrique Dos Santos, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Hugo Valadares Siqueira, Doutorado - Universidade Tecnológica Federal do Paraná

Dra. Mariana Gomes Da Motta Macedo, Doutorado - Universite de Toulouse Iii

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 30/08/2023.

*“It's amazing that a man who is dead can talk to people through these pages. As long as this book survives, his ideas live.”*

(PAOLINI, C., 2003)

## RESUMO

Com o crescente aumento no consumo de energia gerado pelo avanço tecnológico a eficiência no uso de energia se torna cada dia mais importante. A perda de energia na forma de calor é um problema comum em quase todas as áreas da indústria e trocadores de calor tem um papel essencial no aumento da eficiência e diminuição do desperdício. Tubos de calor e termossifões são trocadores de calor conhecidos pela alta versatilidade e alta eficiência em sistemas. Em contraste com a sua alta utilidade, esses dispositivos têm, em muitos casos, equações teóricas complexas com altas porcentagens de erro que podem limitar o seu desenvolvimento e causar a dependência de métodos empíricos que geram perdas de tempo e material, resultando em maiores gastos e diminuindo a viabilidade de sua utilização. Assim, técnicas que utilizam inteligência computacional como as Redes Neurais Artificiais (RNA) podem ser uma excelente opção para facilitar a construção e desenvolvimento desse tipo de equipamento, uma vez que são capazes de gerar bons resultados sem um conhecimento da complexa teoria por trás do problema. As RNA, são algoritmos computacionais baseados no sistema nervoso dos organismos superiores, que conseguem resolver problemas complexos utilizando dados experimentais acerca do problema em questão. Esses algoritmos usam dados conhecidos do sistema proposto para “aprender” o seu comportamento. Uma RNA pode, em muitos casos, alcançar resultados tão bons ou mesmo melhores do que aqueles obtidos por métodos analíticos e são limitadas apenas à qualidade do banco de dados e pelo poder computacional disponível. Esta investigação usa dados experimentais de estudos anteriores para avaliar a capacidade da RNA em prever o desempenho térmico de termossifões e tubos de calor. Um banco de dados composto por termossifões e tubos de calor foi organizado e as redes neurais foram aplicadas com o objetivo de avaliar a sua capacidade de simular os sistemas propostos. As redes neurais utilizadas foram: *Perceptron* de Múltiplas Camadas (MLP), a Rede Neural com Função de Base Radial (RBF) e a Máquina de Aprendizado Extremo (ELM). Como entradas para as redes neurais foram utilizadas as propriedades de projeto e como saída é esperada a resistência térmica dos termossifões e tubos de calor. Os resultados encontrados mostram que as RNA têm capacidade de simular as propriedades dos termossifões e tubos de calor. Os melhores resultados para os termossifões apresentaram Erro Percentual Absoluto Médio (*MAPE*) menor que 6,00% com a utilização da Rede ELM. Para os tubos de calor, o menor erro foi conseguido com a Rede MLP resultando em um *MAPE* de cerca de 13,93%. Assim, a utilização de RNA no desenvolvimento de termossifões e tubos de calor se mostra uma ótima opção para acelerar e melhorar a fase de projetos, diminuindo perdas de material, tempo e outros recursos.

Palavras-chave: máquina de aprendizado extremo; máquinas desorganizadas; mudança de fase; desempenho térmico.

## ABSTRACT

With the increasing energy consumption generated by technological advances, efficiency in energy use becomes more important every day. The loss of energy in the form of heat is a common problem in almost all areas of industry, and heat exchangers play an essential role in increasing efficiency and reducing energy waste. Heat pipes and thermosyphons are heat exchangers known for their high versatility and high efficiency in systems. In contrast to their high utility, these devices have, in many cases, complex theoretical equations with high percentages of error that can limit their development and cause dependence on empirical methods that generate waste of time and material, resulting in significant expenses and reducing the viability of its use. Thus, techniques that use computational intelligence, such as Artificial Neural Networks (ANN), can be an excellent option to facilitate the construction and development of this type of equipment since they can generate good results without knowledge of the complex theory behind the problem. ANN are computational algorithms based on the nervous system of higher organisms, which can solve complex problems using experimental data about the problem in question. These algorithms use known data from the proposed system to “learn” its behavior. In many cases, an ANN can achieve results as good or even better than those obtained by analytical methods and are limited only by the quality of the database and the available computational power. This investigation uses experimental data from previous studies to evaluate the ability of ANN to predict the thermal performance of thermosyphons and heat pipes. A database of thermosyphons and heat pipes was organized and applied to neural networks to evaluate their ability to simulate the proposed systems. The neural networks used are the Multilayer Perceptron (MLP), the Neural Network with Radial Basis Function (RBF), and the Extreme Learning Machine (ELM). Design properties were used as inputs to the neural networks, and the thermal resistance of thermosyphons and heat pipes was expected as output. The results show that the ANN can successfully simulate the properties of thermosyphons and heat pipes. The best results for thermosyphons showed Mean Absolute Percentage Error (*MAPE*) of less than 6.00% using the ELM network. The lowest error for heat pipes was achieved with the MLP network, resulting in a *MAPE* of around 13.93%. Thus, using ANN in developing thermosyphons and heat pipes is an excellent option for accelerating and improving the project phase, reducing the loss of material, time and other resources.

Keywords: extreme learning machine; unorganized machines; phase change; thermal performance.

## LISTA DE FIGURAS

Figura 1 - Princípio de funcionamento de um termossifão .....	21
Figura 2 - Principais estruturas capilares de tubos de calor.....	25
Figura 3 - Associação de resistências térmicas de um tubo de calor .....	27
Figura 4 - Diagrama esquemático das dimensões das microranhuras utilizadas na Equação (19).....	30
Figura 5 - Representação de uma RNA .....	32
Figura 6 - Representação de um neurônio biológico .....	33
Figura 7 - Estrutura do neurônio artificial .....	34
Figura 8 - Arquitetura de uma RNA <i>Feedforward</i> de múltiplas camadas com duas camadas ocultas .....	35
Figura 9 - RNA recorrente.....	36
Figura 10 - Representação gráfica de uma RNA-MLP com duas camadas intermediárias.....	37
Figura 11 - Funções de ativação sigmoóde e tangente hiperbólica .....	38
Figura 12 - Função <i>Gaussiana</i> .....	42
Figura 13 - Variação da forma da Função <i>Gaussiana</i> com diferentes desvios padrão .....	44
Figura 14 - Agrupamento de dados de entrada bidimensionais .....	44
Figura 15 - Diagrama do procedimento experimental para coleta de dados .....	55
Figura 16 - Tipos de microranhuras axiais utilizadas .....	57
Figura 17 - Desenho esquemático do aparato experimental - Krambeck (2018).....	60
Figura 18 - Configuração da Rede MLP utilizada .....	63
Figura 19 - Rede RBF .....	66
Figura 20 - Rede ELM.....	68

## LISTA DE FOTOGRAFIAS

<b>Fotografia 1 - Aparato experimental .....</b>	<b>55</b>
<b>Fotografia 2 - Aparato experimental - Nishida (2016).....</b>	<b>57</b>
<b>Fotografia 3 - Amostra das diferentes configurações de estruturas capilares de pó de cobre sinterizadas .....</b>	<b>59</b>
<b>Fotografia 4 - Configurações de malhas .....</b>	<b>61</b>

## LISTA DE GRÁFICOS

Gráfico 1 - Faixa de temperatura de operação para fluidos de trabalho comumente utilizados.....	23
Gráfico 2 - Figura de mérito para alguns fluidos de trabalho.....	24
Gráfico 3 - Diagrama de caixa para o <i>MAPE</i> das 30 simulações - termossifões	71
Gráfico 4 - Diagrama de caixa para o <i>MAE</i> das 30 simulações - termossifões..	71
Gráfico 5 - Diagrama de caixa para o <i>RMSE</i> das 30 simulações - termossifões	72
Gráfico 6 - Comparação entre os valores experimentais e calculados para cada RNA com o valor experimental para os dados de termossifões.....	72
Gráfico 7 - Relação entre erro ( <i>MAPE</i> ) e número de neurônios para a Rede ELM .....	74
Gráfico 8 - Relação entre erro ( <i>MAPE</i> ) e número de neurônios para a Rede RBF .....	75
Gráfico 9 - Relação entre erro ( <i>MAPE</i> ) e número de neurônios para a Rede MLP .....	76
Gráfico 10 - Diagrama de caixa para o <i>MAPE</i> das 30 simulações para as redes neurais utilizadas (tubos de calor) .....	77
Gráfico 11 - Diagrama de caixa para o <i>MAE</i> das 30 simulações para as redes neurais utilizadas (tubos de calor) .....	78
Gráfico 12 - Diagrama de caixa para o <i>RMSE</i> das 30 simulações para as redes neurais utilizadas (tubos de calor) .....	78
Gráfico 13 - Comparação entre os valores experimentais e calculados para cada RNA com o valor experimental para os dados de tubos de calor.....	79
Gráfico 14 - Comparação entre os valores experimentais e calculados para cada RNA com o valor experimental para os dados de tubos de calor para resistências térmicas menores que 1,2K/W .....	80

## LISTA DE QUADROS

<b>Quadro 1 - Resistências térmicas de um tubo de calor segundo Reay, Kew e McGlen (2014).....</b>	<b>28</b>
<b>Quadro 2 - Características geométricas dos termossifões e tubos de calor utilizados.....</b>	<b>54</b>
<b>Quadro 3 - Valores utilizados no Treinamento .....</b>	<b>62</b>
<b>Quadro 4 - Erros encontrados para a melhor configuração de cada rede - termossifões.....</b>	<b>70</b>
<b>Quadro 5 - Erros encontrados para a melhor configuração de cada rede – tubos de calor .....</b>	<b>73</b>

## LISTA DE TABELAS

<b>Tabela 1 - Informações sobre os parâmetros utilizados por Aguiar (2016) .....</b>	<b>56</b>
<b>Tabela 2 - Informações sobre os parâmetros utilizados nos testes selecionados - NISHIDA (2016) .....</b>	<b>58</b>
<b>Tabela 3 - Parâmetros utilizados nos testes dos dados selecionados - Krambeck (2018).....</b>	<b>60</b>
<b>Tabela 4 - Informações sobre os parâmetros utilizados nos testes selecionados - Krambeck (2016) .....</b>	<b>61</b>

## LISTA DE ABREVIATURA E SIGLAS

RNA	Redes Neurais Artificiais
MLP	<i>Multilayer Perceptron</i> ( <i>Perceptron</i> de Múltiplas Camadas)
ELM	<i>Extreme Learning Machine</i> (Máquina de Aprendizado Extremo)
RBF	<i>Radial Base Function</i> (Rede Função de Base Radial)
MAE	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
MAPE	<i>Mean Absolute Percentage Error</i> (Erro Percentual Absoluto Médio)
RMSE	<i>Root Mean Squared Error</i> (Raiz do Erro Quadrático Médio)

## LISTA DE SÍMBOLOS

### Letras Latinas

$c$	Valor de centro da <i>Gaussiana</i>	[ ]
$d$	Distância entre centros das <i>Gaussianas</i>	[ ]
$e$	Sinal de erro	[ ]
$E$	Função erro	[ ]
$h$	Calor latente de vaporização	[J/kg]
$k$	Condutividade térmica	[W/m.K]
$M$	Número de mérito	[W/m <sup>2</sup> ]
$T$	Temperatura	[K]
$w$	Peso de um neurônio de uma rede neural	[ ]
$W$	Matriz de pesos	[ ]
$x$	Entrada de uma rede neural	[ ]
$X$	Matriz de entradas	[ ]
$y$	Saída de uma rede neural	[ ]
$Y$	Matriz de saídas	[ ]

## Letras Gregas

$\mu$	Viscosidade dinâmica	[Pa.s]
$\rho$	Massa específica	[kg/m <sup>3</sup> ]
$\sigma$	Desvio padrão	[ ]
$\beta$	Matriz de pesos treinados (ELM)	[ ]
$\varphi$	Função de ativação	[ ]
$\delta$	Função de erro retropropagado	[ ]

## Subscritos

<i>adiab</i>	Seção adiabática
<i>cond</i>	Condensador
<i>evap</i>	Evaporador
<i>máx</i>	Máximo
<i>th</i>	Térmica

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>16</b>
1.1	Tubos de calor e termossifões.....	16
1.2	Redes Neurais Artificiais .....	17
1.3	Justificativa.....	18
1.4	Objetivos .....	18
1.4.1	Objetivo geral.....	18
1.4.2	Objetivos específicos.....	19
<b>2</b>	<b>TUBOS DE CALOR E TERMOSSIFÕES .....</b>	<b>20</b>
2.1	Introdução .....	20
2.2	Funcionamento e componentes de um tubo de calor e/ou termossifão .....	20
2.2.1	Invólucro.....	22
2.2.2	Fluido de trabalho.....	22
2.2.3	Estrutura capilar.....	24
2.3	Termossifões .....	26
2.4	Projeto térmico de um tubo de calor .....	26
<b>3</b>	<b>REDES NEURAIIS ARTIFICIAIS .....</b>	<b>31</b>
3.1	Introdução .....	31
3.2	Modelos de neurônios artificiais bioinspirados .....	33
3.3	Arquiteturas de Redes Neurais Artificiais .....	34
3.4	<i>Perceptron</i> de Múltiplas Camadas .....	36
3.4.1	Funcionamento de uma MLP.....	37
3.4.2	<i>Backpropagation</i> .....	38
3.4.3	Treinamento da MLP e validação cruzada.....	40
3.5	Rede Função de Base radial.....	41
3.5.1	Treinamento de uma RBF.....	42
3.5.2	<i>k-means</i> .....	45
3.5.2.1	<u>Otimização por Enxame de Partículas .....</u>	<u>45</u>
3.6	Máquinas de Aprendizado Extremo .....	47
3.6.1	Inversa generalizada de <i>Moore-Penrose</i> .....	47
3.6.2	Treinamento de Máquinas de Aprendizado Extremo.....	48
<b>4</b>	<b>ESTADO DA ARTE.....</b>	<b>50</b>

<b>5</b>	<b>BANCO DE DADOS .....</b>	<b>54</b>
<b>5.1</b>	<b>Termossifões .....</b>	<b>54</b>
5.1.1	Procedimento experimental para a aquisição de dados.....	55
<u>5.1.1.1</u>	<u>Dados utilizados .....</u>	<u>56</u>
<b>5.2</b>	<b>Tubos de calor .....</b>	<b>56</b>
5.2.1	Ranhuras axiais.....	56
<u>5.2.1.1</u>	<u>Dados utilizados .....</u>	<u>58</u>
5.2.2	Pó Metálico Sinterizado.....	58
<u>5.2.2.1</u>	<u>Dados utilizados .....</u>	<u>60</u>
5.2.3	Tela metálica.....	60
<u>5.2.3.1</u>	<u>Dados utilizados .....</u>	<u>61</u>
<b>6</b>	<b>METODOLOGIA .....</b>	<b>62</b>
<b>6.1</b>	<b>Treinamento das RNA .....</b>	<b>62</b>
6.1.1	MLP .....	63
6.1.2	RBF .....	65
6.1.3	ELM .....	67
<b>7</b>	<b>RESULTADOS.....</b>	<b>69</b>
<b>7.1</b>	<b>Termossifões .....</b>	<b>70</b>
<b>7.2</b>	<b>Tubos de calor .....</b>	<b>73</b>
<b>8</b>	<b>CONCLUSÃO .....</b>	<b>82</b>
<b>8.1</b>	<b>Sugestão para trabalhos futuros .....</b>	<b>83</b>
	<b>REFERÊNCIAS.....</b>	<b>84</b>
	<b>APÊNDICE A – Dados utilizados (Termossifões) .....</b>	<b>91</b>
	<b>APÊNDICE B – Dados utilizados (tubos de calor) .....</b>	<b>94</b>

## **1 INTRODUÇÃO**

Com o aumento da demanda energética decorrente da crescente modernização e industrialização da sociedade atual, o aumento da eficiência dos equipamentos é completamente indispensável no gerenciamento dessa demanda e na construção de uma matriz elétrica cada vez mais sustentável. Antes mesmo de entrar em contato com o consumidor final, as fontes de energia mais comuns, como a eletricidade e a gasolina, devem passar por diversas transformações para que possam ser devidamente utilizadas. Em cada processo realizado, é perdida parte da energia gerada, fazendo com que apenas uma fração dessa chegue ao consumidor final e, mesmo neste ponto, a utilização da energia é muitas vezes ineficiente (NASCIMENTO, 2015).

A perda de energia na forma de calor pela ineficiência de dispositivos, tem grande impacto no uso da energia em escalas globais. Cullen e Allwood (2010) estimam que a perda energética relacionada à perda de calor em consumo de energia primária, aquela que ainda não sofreu nenhum tipo de transformação, alcança cerca de 63% da energia consumida. Mesmo uma parcela desse calor, se aproveitada, pode influenciar positivamente as demandas energéticas inerentes ao próprio setor responsável pelo desperdício, reduzindo o impacto monetário e ambiental do aumento da produção de energia necessária para suprir essas perdas.

A criação de novas tecnologias e o desenvolvimento contínuo dos equipamentos já utilizados é um importante processo para o aumento da eficiência na utilização da energia. Mesmo que esse processo de desenvolvimento possa ser muitas vezes lento, a cada dia, novas tecnologias estão disponíveis para facilitar e acelerar esse processo.

### **1.1 Tubos de calor e termossifões**

A necessidade de aumentar a eficiência no aproveitamento do calor nos leva aos tubos de calor e/ou termossifões, dispositivos passivos capazes de transferir grandes quantidades de calor, mesmo com pequenas diferenças de temperaturas.

Esses dispositivos são construídos a partir de tubos, em que suas superfícies internas podem ser revestidas com estruturas capilares que são posteriormente, evacuados, preenchidos com fluido de trabalho e selados. O tubo evacuado tem pressão controlada, permitindo que o fluido de trabalho mude de fase com mais

facilidade. O funcionamento dos tubos de calor e/ou termossifões se inicia com a troca de calor do fluido de trabalho com a fonte quente, que faz com que o fluido de trabalho mude da fase líquida para a fase gasosa e carregue o calor em direção à fonte fria. Então, o fluido de trabalho perde calor e muda para a fase líquida, reiniciando o ciclo. O bombeamento do fluido de trabalho acontece por meio do fenômeno de capilaridade e depende das estruturas capilares adicionadas ao tubo de calor. Termossifões são tubos de calor que utilizam a gravidade para o bombeamento do fluido, evitando assim, a necessidade de uma estrutura capilar. Esses dispositivos possuem uma construção e projeto mais simples, porém, mais limitados em relação à inclinação em que o dispositivo pode trabalhar e são inviáveis em condições de baixa gravidade (REAY; KEW; MCGLEN, 2014).

Mesmo com o grande desenvolvimento da área, diferentes modelos de tubos de calor e termossifões ainda são estudados e desenvolvidos e, para muitos desses casos, é necessária uma modelagem teórica com grande complexidade vinda principalmente das características convectiva e de mudança de fase dos processos envolvidos. A dificuldade no seu modelamento leva, muitas vezes, a limitações na viabilidade da utilização desses dispositivos passivos de transferência de calor. Modelos computacionais, como as Redes Neurais Artificiais, podem ter um papel importante em reduzir os principais problemas causados por essa dificuldade encontrada no modelamento desses e outros dispositivos térmicos.

## **1.2 Redes Neurais Artificiais**

As Redes Neurais Artificiais (RNA) são modelos computacionais construídos baseando-se 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. Assim, é possível “ensinar” a rede neural sobre o comportamento de problemas complexos (HAYKIN, 2008).

Uma RNA em prática tenta replicar, principalmente, duas características do cérebro: a capacidade de aprender informações sobre o ambiente se utilizando de uma técnica de aprendizado e a capacidade de armazenar informação nas conexões entre suas unidades de processamento chamadas neurônios. Além disso, o poder computacional de uma RNA deriva da sua estrutura distribuída e sua capacidade de

aprender e generalizar. Generalizar indica a capacidade da rede em prever informações não utilizadas durante o seu treinamento (HAYKIN, 2008).

### **1.3 Justificativa**

A criação de modelos teóricos precisos de tubos de calor e/ou termossifões envolve complexas formulações para o seu funcionamento, que envolvem mudanças de fase e convecção. Desta forma, é necessário, em muitos casos, a utilização de métodos empíricos e da prototipação de modelos, para que se possa ter com precisão as características de funcionamento de um dado dispositivo.

Este tipo de desenvolvimento gera, em muitos casos, retrabalho já que não se pode garantir os resultados esperados durante a montagem do protótipo. Como resultado, se tem desperdício de tempo e material, além de consequentes gastos que, muitas vezes, limitam o crescimento e o investimento na área.

É esperado que a utilização de RNA possa ser capaz de reduzir os problemas encontrados durante o desenvolvimento de termossifões e tubos de calor, uma vez que esses algoritmos não são dependentes da complexa teoria por trás do problema e necessitam apenas de dados experimentais. Caso as RNA sejam capazes de modelar corretamente o problema, elas poderiam ser utilizadas durante a fase de planejamento para gerarem previsões mais precisas acerca dos equipamentos a serem construídos, diminuindo os erros e consequente retrabalho.

Neste contexto, avaliar os possíveis avanços da utilização de RNA na previsão do desempenho térmico de tubos de calor e/ou termossifões se mostra importante para o desenvolvimento da área e objetiva este estudo de mestrado.

### **1.4 Objetivos**

Para a realização desta Dissertação de Mestrado foram definidos objetivos, geral e específicos, apresentados nesta seção.

#### **1.4.1 Objetivo geral**

O presente estudo tem como objetivo geral investigar a aplicação de diferentes Redes Neurais Artificiais na avaliação e aperfeiçoamento do projeto de tubos de calor e termossifões, gerando previsões de suas resistências térmicas a partir de seus dados de projeto, como dimensões, inclinação de trabalho, fluido de trabalho e

temperatura de operação, acelerando assim, o planejamento e a modelagem de novos protótipos.

#### 1.4.2 Objetivos específicos

Como objetivos específicos desse estudo tem-se:

- avaliar os diversos modelos de Redes Neurais Artificiais e suas diferentes características;
- escolher as RNA a serem utilizadas para a realização do trabalho;
- desenvolver os algoritmos para as redes neurais a serem utilizadas;
- aplicar as RNA selecionadas para o problema proposto;
- comparar os resultados obtidos: experimental e com a utilização das RNA;
- avaliar a eficiência das redes neurais na generalização do problema.

## 2 TUBOS DE CALOR E TERMOSSIFÕES

Nesta seção são apresentados conceitos sobre o funcionamento e as principais características de tubos de calor e termossifões, assim como sua importância para esse trabalho.

### 2.1 Introdução

O tubo de calor é um dispositivo passivo de transporte de energia de alta eficiência e extrema versatilidade. Nele, grandes quantidades de energia na forma de calor podem ser transportadas por meio de uma pequena área transversal e por distâncias consideráveis, sem a utilização de nenhum tipo de bombeamento ativo e mesmo entre pequenos gradientes de temperatura. Além disso, a construção de tubos de calor possui certa simplicidade de projeto e fabricação por utilizar, em grande parte, componentes de fácil obtenção e preços acessíveis (FAGHRI, 2014).

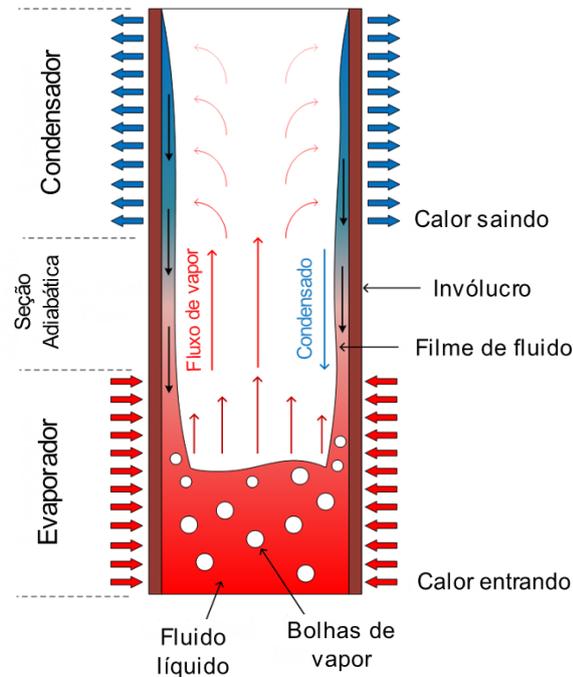
Como esse dispositivo se beneficia da ação capilar, alguns tipos de tubos de calor podem operar mesmo em condições de microgravidade sem uma força externa de bombeamento. Grande parte do desenvolvimento inicial da área ocorreu pelos estudos direcionados a aplicação espacial, mesmo assim, com a eficiência energética se tornando cada vez mais importante, não demorou muito para que países como o Japão se interessassem pela importância das aplicações terrestres desses dispositivos, que rapidamente se tornaram de grande importância em diversos setores industriais. Nas últimas décadas, o aumento da necessidade de controle térmico em dispositivos eletroeletrônicos proporcionou aos tubos de calor ainda mais importância e causou uma nova transformação na área, que hoje é altamente utilizada para o resfriamento de processadores em computadores, *smartphones* e outros dispositivos (NISHIDA, 2016).

### 2.2 Funcionamento e componentes de um tubo de calor e/ou termossifão

Mesmo sendo um componente versátil e podendo ser construído em diversos tamanhos e formatos, o princípio de funcionamento de um tubo de calor e/ou termossifão é sempre o mesmo. Como mostrado na Figura 1, um termossifão pode ser dividido em três diferentes partes: evaporador, seção adiabática e condensador. A região do evaporador se mantém em contato com a fonte quente enquanto a região

do condensador é responsável por transferir o calor à fonte fria, enquanto a seção adiabática não troca calor e é mantida isolada do meio podendo, em alguns casos, não estar presente.

**Figura 1 - Princípio de funcionamento de um termossifão**



Fonte: MACHADO *et al.* (2023).

Na construção de tubos de calor, o invólucro com a estrutura capilar é evacuado e preenchido com fluido de trabalho em uma quantidade previamente especificada, permitindo o controle da pressão interna do dispositivo. Assim, o fluido de trabalho deve estar em uma dada pressão e temperatura, durante o seu funcionamento, que permita o fluido de trabalho evaporar com facilidade ao receber calor. Dadas essas condições, o ciclo de funcionamento de um tubo de calor se inicia quando calor é recebido pelo evaporador, o que faz com que o fluido de trabalho mude de fase, de líquido para vapor, e se mova em direção ao condensador por diferença de pressão. No condensador, o calor transportado, é rejeitado para o meio externo e, assim, o fluido de trabalho retorna a sua fase líquida e é bombeado novamente para o evaporador, com a ajuda do efeito de capilaridade, reiniciando o ciclo (GROLL; RÖSLER, 1992).

O efeito capilar acontece por meio de uma estrutura capilar adicionada às paredes internas do tubo de calor. Essa estrutura é de grande importância, pois permite que o tubo de calor opere com o evaporador e condensador em quaisquer

posições e, também, em condições de microgravidade. Informações mais detalhadas sobre o funcionamento de tubos de calor e/ou termossifões podem ser encontradas em Chi (1976), Peterson (1994), Reay, Kew e McGlen (2014) e Mantelli (2021).

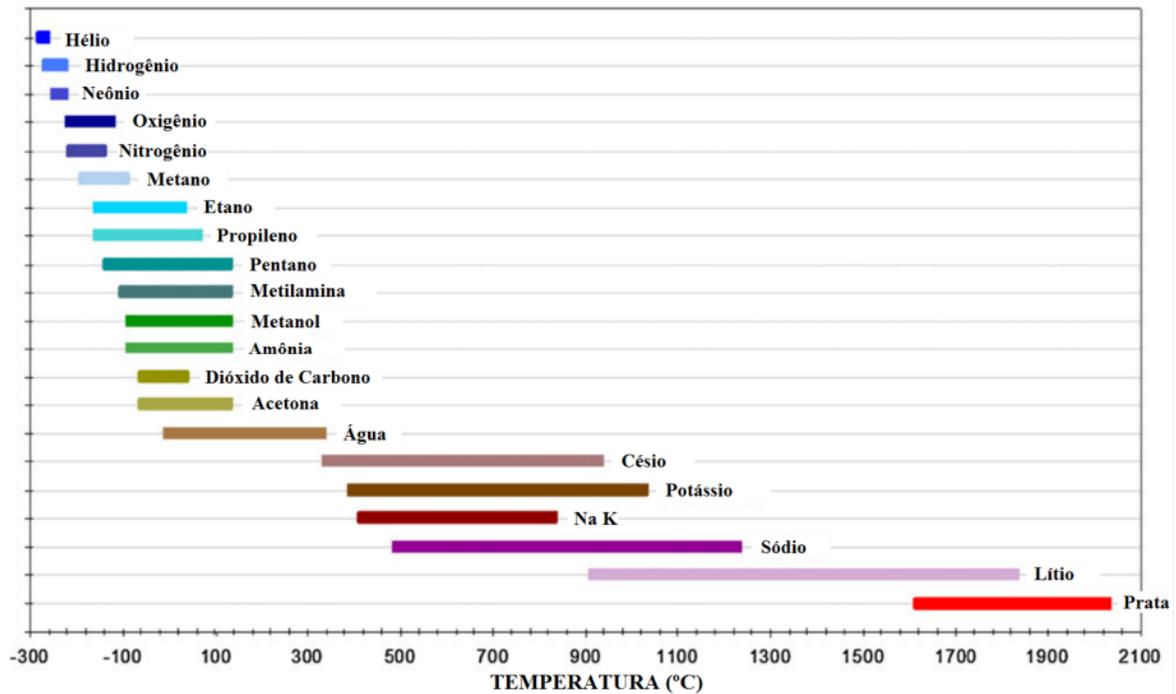
### 2.2.1 Invólucro

O involucro do tubo de calor e/ou termossifão é a estrutura responsável por isolar o fluido de trabalho do meio externo e suportar as diferenças de pressão existentes entre eles. Para isso, é importante que o material escolhido tenha resistência o suficiente para manter a estabilidade estrutural sob essas condições, além de ser compatível com o fluido de trabalho e com o material utilizado para o meio poroso, evitando assim, reações químicas internas indesejadas e/ou a geração de gases que possam diminuir a eficiência da operação. A condutividade térmica do material utilizado também tem grande importância para que o material não interfira na troca de calor entre o meio externo e o fluido de trabalho. Outros fatores utilizados para a seleção de tubos de calor e/ou termossifões são: facilidade de fabricação, preço do material, temperatura de operação, resistência à corrosão, entre outros.

### 2.2.2 Fluido de trabalho

O fluido de trabalho é a base do funcionamento do tubo de calor e/ou termossifão, sendo assim, a seleção de um fluido de trabalho correto é uma etapa importante do projeto. A escolha do fluido de trabalho se inicia com a definição da sua faixa de temperatura de operação, fator indispensável uma vez que trabalhar abaixo ou acima da temperatura e pressão corretas pode levar o fluido de trabalho a não transitar entre as fases líquida e gasosa, tornando o dispositivo ineficiente. Mesmo que grande parte das aplicações envolvam fluidos de trabalho com temperaturas de ebulição entre  $-25^{\circ}\text{C}$  e  $100^{\circ}\text{C}$ , em que a água é amplamente utilizada, existem também tubos de calor e/ou termossifões chamados criogênicos, que operam na faixa de temperatura entre  $-270^{\circ}\text{C}$  e  $-50^{\circ}\text{C}$  e tubos de calor e/ou termossifões de metal líquido, que operam entre  $450^{\circ}\text{C}$  e  $2.000^{\circ}\text{C}$  (YANG *et al.*, 2012). O Gráfico 1 apresenta as faixas de temperatura de operação dos fluidos de trabalho mais utilizados.

Gráfico 1 - Faixa de temperatura de operação para fluidos de trabalho comumente utilizados

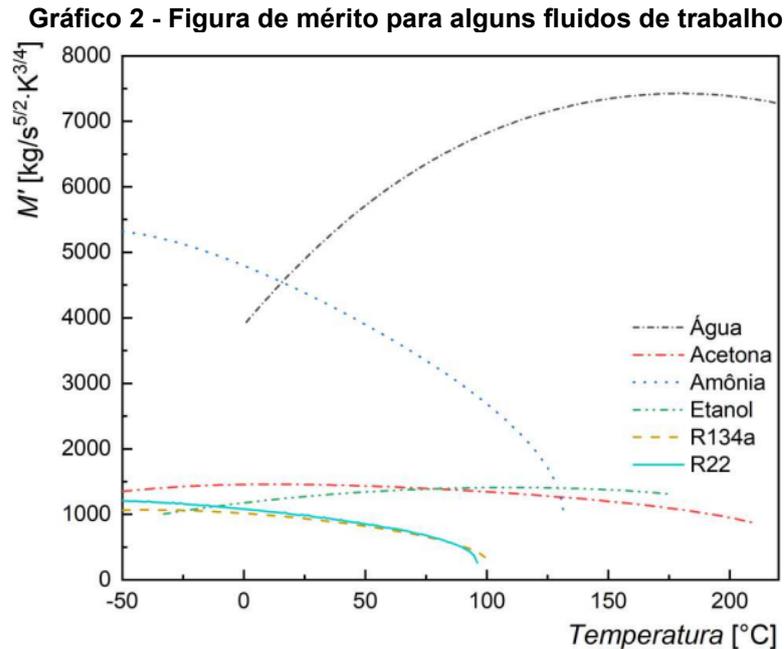


Fonte: Adaptado de YANG *et al.* (2012).

Conhecendo as temperaturas de operação desejadas, também é possível estimar o fluido de trabalho que apresentará melhores resultados para uma dada configuração, por meio da determinação da Figura de Mérito,  $M'$ , expressa pela Equação (1):

$$M' = \left( \frac{h_V k_l^3 \rho_l^2}{\mu_l} \right)^{1/4}, \quad (1)$$

sendo que,  $h_V$  é o calor latente de vaporização do fluido,  $k_l$ ,  $\rho_l$  e  $\mu_l$  representam, respectivamente, a condutividade térmica, massa específica e viscosidade dinâmica da fase líquida. Os valores da Figura de Mérito para alguns fluidos de trabalho são mostrados no Gráfico 2 (MACHADO, 2022).



A partir do Gráfico 2, pode ser notado que para a faixa de 20°C a 200°C, a água é o melhor fluido de trabalho entre os considerados, o que justifica a grande utilização dela como fluido de trabalho para resfriamento de equipamentos eletroeletrônicos, que normalmente atuam nessa faixa de temperatura de operação.

Alguns outros fatores têm grande importância na seleção do fluido de trabalho, como sua condutividade térmica, toxicidade e estabilidade. Também é importante que o fluido de trabalho utilizado, o meio poroso e o invólucro sejam compatíveis entre si evitando reações que liberam substâncias não desejadas e corrosão.

### 2.2.3 Estrutura capilar

A estrutura capilar de um tubo de calor tem como objetivo bombear passivamente o fluido de trabalho da região do condensador para a região do evaporador. Para a escolha de uma estrutura adequada, três propriedades muito importantes devem ser levadas em consideração: a permeabilidade, a condutividade térmica e o raio crítico dos poros. O poro deve ter um raio crítico pequeno para que se tenha uma boa pressão capilar necessária para bombear o fluido de trabalho. A permeabilidade deve ser alta para que se obtenha uma pequena queda de pressão do líquido na estrutura capilar. Enquanto uma boa condutividade térmica, é essencial para que a existência da estrutura capilar gere pouca resistência na transferência de calor entre o fluido de trabalho e o meio exterior (SHABANY, 2010).

Em muitos casos, o tamanho de raio dos poros e a permeabilidade são inversamente relacionadas, ou seja, para que se melhore uma característica há uma perda em outra. Elnaggar (2014) afirma que, uma diminuição do tamanho do poro diminui a permeabilidade da estrutura porosa e aumenta a capacidade de bombeamento, permitindo superar a queda de pressão dentro do tubo de calor. Em contrapartida, a diminuição da permeabilidade aumenta a queda de pressão do líquido e diminui a capacidade de transporte de calor. Assim, chegar a um equilíbrio entre essas características é parte importante do projeto de um tubo de calor. A Figura 2 mostra alguns tipos comuns de estruturas capilares utilizadas em tubos de calor e suas principais características.

**Figura 2 - Principais estruturas capilares de tubos de calor**

Tipo de Meio Poroso	Bombeamento Capilar	Condutividade Térmica	Permeabilidade	Comentários
 A. Tela Metálica	Alto	Alta	Média-Baixa	Única ou Múltiplas Camadas de Telas de Fio
 B. Metal Sinterizado	Alto	Média	Média-Baixa	Partículas Esféricas Empacotadas, Metal em Fibra ou em Pó
 C. Ranhuras Axiais	Baixo	Alta	Média-Alta	Ranhuras Retangular, Circular, Triangular ou Trapezoidal

Fonte: Adaptado de FAGHRI (1995).

A utilização de telas metálicas como estrutura capilar é uma das mais comuns devido, principalmente, ao fácil acesso a essas estruturas e a sua fácil implementação. As telas podem ser feitas de metais como aço inoxidável, bronze e cobre que são conformadas e inseridas na parte interna do invólucro (NISHIDA, 2016).

Estruturas de metal sinterizado são produzidas pelo processo de sinterização, em que pó metálico é mantido sob pressão e temperatura controlada, criando um material de características únicas, formadas pela união parcial das partículas de pó. Para a utilização em tubos de calor, o metal pode ser sinterizado diretamente dentro

do tubo metálico que é, então, aquecido. O resultado é uma estrutura com boa condutividade térmica e com poros reduzidos (KHALILI; SHAFILI, 2016).

Estruturas de ranhuras axiais possuem uma elevada condutividade térmica e boa permeabilidade, devido às grandes dimensões das ranhuras, se comparadas aos poros de estruturas como tela metálica e metal sinterizado, porém, em compensação, apresentam uma pressão capilar relativamente pequena. Por esse motivo, tubos de calor com ranhuras axiais têm bom desempenho em condições em que são favorecidos pela ação da gravidade. A principal desvantagem desse tipo de estrutura é a dificuldade de fabricação dessas ranhuras, principalmente em invólucros de pequena dimensão (NISHIDA *et al.*, 2020).

### **2.3 Termossifões**

Os termossifões são tubos de calor que funcionam apenas com ajuda da gravidade, ou seja, não possuem estrutura capilar, dependendo grandemente da inclinação do invólucro em relação à ação da gravidade. A principal vantagem da utilização desse tipo de dispositivo é a simplicidade de projeto e construção, uma vez que não é necessário projetar ou produzir uma estrutura capilar como nos tubos de calor. Em contrapartida, a sua desvantagem vem da dependência da gravidade, que impede a utilização, por exemplo, em sistemas horizontais.

### **2.4 Projeto térmico de um tubo de calor**

O projeto térmico de um tubo de calor é a fase em que se objetiva encontrar os parâmetros que geram a melhor transferência de calor possível, a partir das dimensões do dispositivo a ser construído. Usualmente, fluxo de calor, temperatura de operação e geometria são previamente definidos pelas características do problema. Assim, devem ser modificados outros parâmetros como, fluido de trabalho, estrutura capilar, razão de preenchimento, entre outros.

O fluido de trabalho pode ser definido utilizando a Figura de Mérito, mostrada no Gráfico 2, enquanto a estrutura capilar depende do tipo de fluido de trabalho utilizado, além da pressão capilar necessária. Definidos os parâmetros necessários, é preciso uma modelagem teórica para estimar a taxa de transferência de calor alcançada pelo tubo de calor projetado. Caso os resultados indiquem que o dispositivo não será adequado, um novo projeto deve ser feito (KRAMBECK, 2016).



**Quadro 1 - Resistências térmicas de um tubo de calor segundo Reay, Kew e McGlen (2014)**

Resistência Térmica	Evaporador	Condensador
Parede - Ambiente Externo	$R_{ext, evap} = \frac{1}{h_{ext, evap} A_{evap}} \quad (3)$	$R_{ext, cond} = \frac{1}{h_{ext, cond} A_{cond}} \quad (4)$
Condutiva na Parede do Tubo	$R_{p, evap} = \frac{\ln\left(\frac{D_{ext}}{D_{int}}\right)}{2\pi l_{evap} k_p} \quad (5)$	$R_{p, cond} = \frac{\ln\left(\frac{D_{ext}}{D_{int}}\right)}{2\pi l_{cond} k_p} \quad (6)$
Condutiva no Meio Poroso	$R_{mp, evap} = \frac{\ln\left(\frac{D_{ext}}{D_{int}}\right)}{2\pi l_{evap} k_{eff}} \quad (7)$	$R_{mp, cond} = \frac{\ln\left(\frac{D_{ext}}{D_{int}}\right)}{2\pi l_{cond} k_{eff}} \quad (8)$
Interface Líquido - Vapor	$R_{mf, evap} = \frac{R_g T_v^2 (2\pi R_g T_v)^{1/2}}{h_{lv}^2 p_v A_{evap}} \quad (9)$	$R_{mf, cond} = \frac{R_g T_v^2 (2\pi R_g T_v)^{1/2}}{h_{lv}^2 p_v A_{cond}} \quad (10)$
Resistência Térmica	Seção Adiabática	
Axial do Vapor	$R_{v, diab} = R_g T_v^2 \frac{\Delta p_v}{h_{lv} p_v q} \quad (11)$	
Axial no Meio Poroso	$R_{mp, diab} \approx 0 \quad (12)$	
Axial na Parede do Tubo	$R_{p, diab} = \frac{l_{evap} + l_{diab} + l_{cond}}{A_{mp} k_{mp} + A_p k_p} \quad (13)$	

Fonte: Adaptado de Reay, Kew e McGlen (2014).

No Quadro 1, que apresentam as Equações (3) a (13),  $h_{ext, evap}$  e  $h_{ext, cond}$  representam os coeficientes de convecção entre as paredes do evaporador e do condensador e o ambiente externo.  $A_{evap}$  e  $A_{cond}$  são as áreas da superfície do evaporador e do condensador.  $D_{ext}$  e  $D_{int}$  são os valores do diâmetro interno e externo do tubo,  $l_{evap}$  e  $l_{cond}$  representam os comprimentos do evaporador e do condensador,  $k_p$  e  $k_{mp}$  são, respectivamente, as condutividades térmicas do fluido de trabalho e da estrutura capilar,  $k_{eff}$  é a condutividade térmica efetiva da estrutura capilar e  $h_{lv}$  e  $p_v$  representam o calor latente de vaporização do fluido de trabalho e a pressão de saturação do fluido, respectivamente.

A queda de pressão de vapor,  $\Delta p_v$ , é definida pela Equação (14):

$$\Delta p_v = \left(1 - \frac{4}{\pi^2}\right) \frac{q^2}{8\rho_v r_v^4 h_{lv}^2} + 8\mu_v q \frac{l_{adiab}}{\rho_v \pi r_v^4 h_{lv}}, \quad (14)$$

em que,  $q$  representa a potência dissipada,  $\rho_v$  é a massa específica do vapor,  $r_v$  é o raio do vapor,  $h_{lv}$  representa o calor latente de vaporização e  $\mu_v$  é a viscosidade dinâmica do vapor.

Segundo Chi (1976), a condutividade efetiva para a estrutura capilar de tela metálica pode ser definida pela Equação (15):

$$k_{eff} = \frac{k_l \left[ (k_l + k_{mp}) - (1 - \varepsilon)(k_l - k_{mp}) \right]}{\left[ (k_l + k_{mp}) \right] + (1 - \varepsilon)(k_l - k_{mp})}, \quad (15)$$

em que,  $k_l$  e  $k_{mp}$  são as condutividades térmicas do fluido e da estrutura capilar, respectivamente, enquanto  $\varepsilon$  é a porosidade. A condutividade térmica do meio poroso,  $k_{mp}$ , é dada pela Equação (16):

$$k_{mp} = \frac{D_{fio}^2 \varepsilon^3}{122(1 - \varepsilon)^2}, \quad (16)$$

enquanto que a porosidade ( $\varepsilon$ ) é definida na Equação (17):

$$\varepsilon = 1 - \frac{1,05\pi N D_{fio}}{4}, \quad (17)$$

em que,  $N$  é o número de malha da tela (*mesh*) e  $D_{fio}$  é o diâmetro do fio da malha.

Chi (1976) também define a equação para a condutividade efetiva para a estrutura capilar de esferas empacotadas pela Equação (18):

$$k_{eff} = \frac{k_l \left[ (k_l + k_{mp}) - 2(1 - \varepsilon)(k_l - k_{mp}) \right]}{\left[ (k_l + k_{mp}) \right] + (1 - \varepsilon)(k_l - k_{mp})}, \quad (18)$$

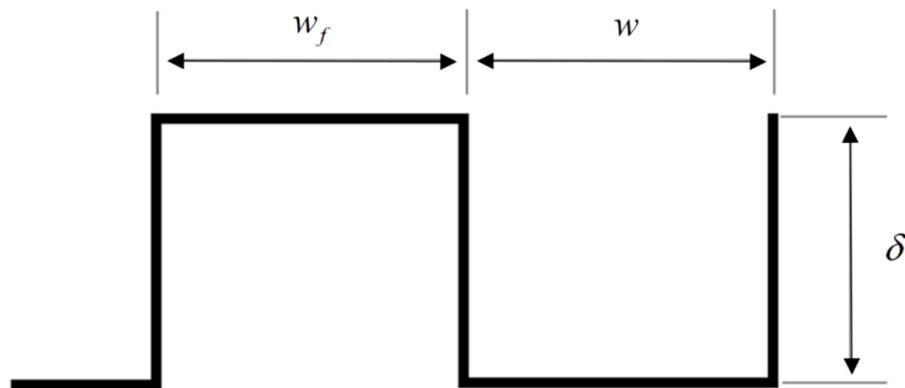
em que,  $\varepsilon$  é a porosidade e  $k_{mp}$  é a condutividade térmica do meio poroso, usualmente encontrados experimentalmente.

A Equação (19) apresenta uma versão da teoria de Chi (1976) para ranhuras retangulares adaptada por Nishida *et al.* (2020) para ranhuras de geometria semicircular:

$$k_{eff} = 0,8925 \frac{(w_f k_l k_{mp} \delta) + w k_l (0,185 w_f k_{mp} + \delta k_l)}{(w + w_f) + w k_l (0,185 w_f k_{mp} + \delta k_l)}, \quad (19)$$

em que,  $w$  é a largura da microranhura,  $w_f$  é a espessura da crista da microranhura e  $\delta$  é a profundidade da microranhura, como vistos na Figura 4.  $k_l$  e  $k_{mp}$  representam a condutividade térmica do líquido e da estrutura capilar, respectivamente.

**Figura 4 - Diagrama esquemático das dimensões das microranhuras utilizadas na Equação (19)**



Fonte: Nishida *et al.* (2020).

### 3 REDES NEURAIS ARTIFICIAIS

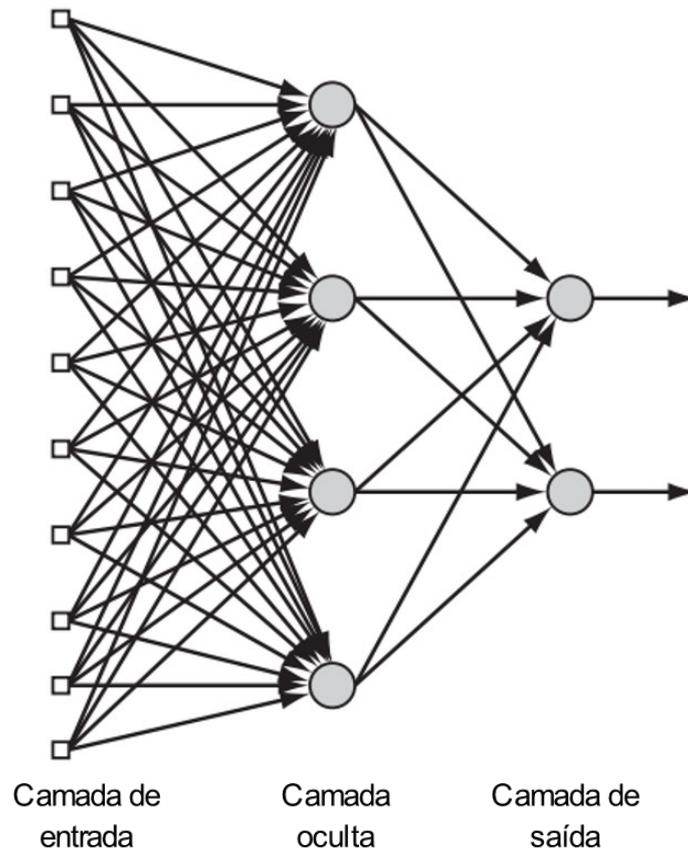
Nesta seção é apresentada uma fundamentação teórica acerca de Redes Neurais Artificiais (RNA) e sua evolução ao longo das últimas décadas. As principais características que levaram ao desenvolvimento de algoritmos bioinspirados são apresentadas, bem como, suas aplicações mais comuns e os principais princípios de funcionamento das RNA mais conhecidas.

#### 3.1 Introdução

Com o aumento constante da capacidade computacional utilizável nas últimas décadas, foi possível, paralelamente, visualizar um crescimento constante na utilização e estudo de métodos que necessitam de alto poder de processamento. Dentre esses, as RNA se destacam pela sua grande gama de aplicação e facilidade de implementação em problemas complexos (HAYKIN, 2008).

As RNA, na visão de Haykin (2008), são modelos computacionais inspirados no sistema nervoso dos animais. Esses algoritmos são formados pela conexão de pequenos módulos, usualmente chamados neurônios, distribuídos em diferentes camadas, como é representado na Figura 5. Esses neurônios simulam o comportamento de neurônios orgânicos, recebendo dados de entrada (à esquerda na Figura 5) e realizando operações matemáticas simples para obter novos valores que serão transmitidos às camadas seguintes até, finalmente, obter resultados da camada de saída (à direita na Figura 5).

A origem das RNA remete ao trabalho pioneiro de *McCulloch e Pitts* (1943), no qual é proposto um modelo simples de neurônio artificial capaz de gerar uma saída binária. A publicação foi inspirada pelos estudos, na época recentes, de *Alan Turing* e *John von Neumann* e pelo conhecimento superficial do funcionamento do neurônio biológico existente na época (KOVÁCS, 2006).

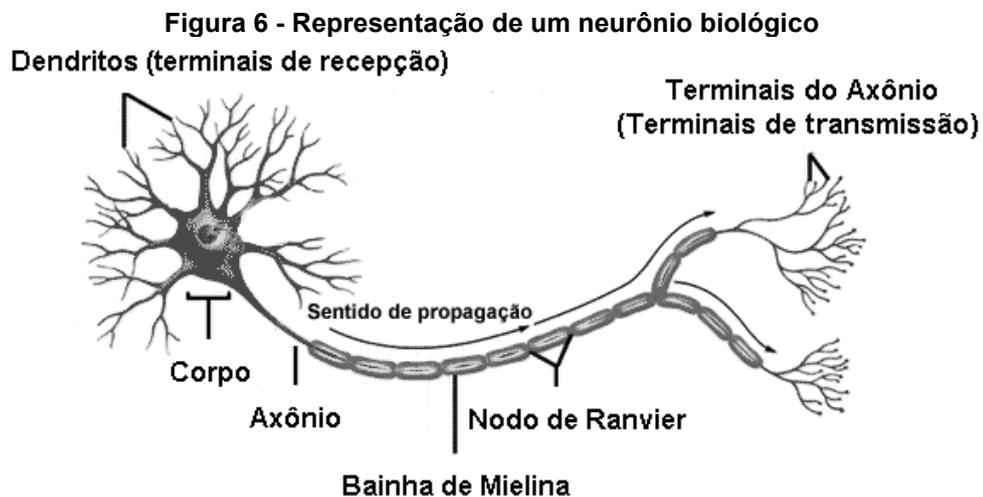
**Figura 5 - Representação de uma RNA**

**Fonte: Adaptado de Haykin (2008).**

Desde então, diversos modelos de RNA foram concebidos, capazes de resolver uma grande diversidade de problemas relacionados a aprendizado e reconhecimento de padrões nas mais diversas situações. Atualmente, essas redes neurais são utilizadas, por exemplo, para: estimar riscos de saúde relacionados à poluição do ar (TADANO *et al.*, 2016; POLEZER *et al.*, 2018; ARAUJO *et al.*, 2020; KACHBA *et al.*, 2020), prever a vida útil de materiais que sofrem fadiga (KUMAR; SWAMY, 2021), previsão de demanda energética a longo prazo (TAI *et al.*, 2021a), previsão da curva de potência para turbinas eólicas (TAI *et al.*, 2021b), previsões de séries temporais (MATTOS *et al.*, 2020; CAMPOS *et al.*, 2020; SIQUEIRA *et al.*, 2020; BELOTTI *et al.*, 2020), entre diversos outros.

### 3.2 Modelos de neurônios artificiais bioinspirados

O neurônio biológico, que pode ser visto na Figura 6, é um tipo de célula encontrada em animais, capaz de criar conexões entre si ao receber estímulos. A estrutura desse tipo de célula geralmente é composta por um corpo celular, em que estão localizadas as organelas celulares, ramificações chamadas dendritos e o axônio, uma prolongação revestida por uma camada lipídica responsável por conduzir impulsos nervosos. O axônio se conecta aos dendritos de outros neurônios, para que haja uma “comunicação” entre esses. Essa conexão é conhecida como sinapse (OLIVEIRA, 2011).



Fonte: Oliveira (2011).

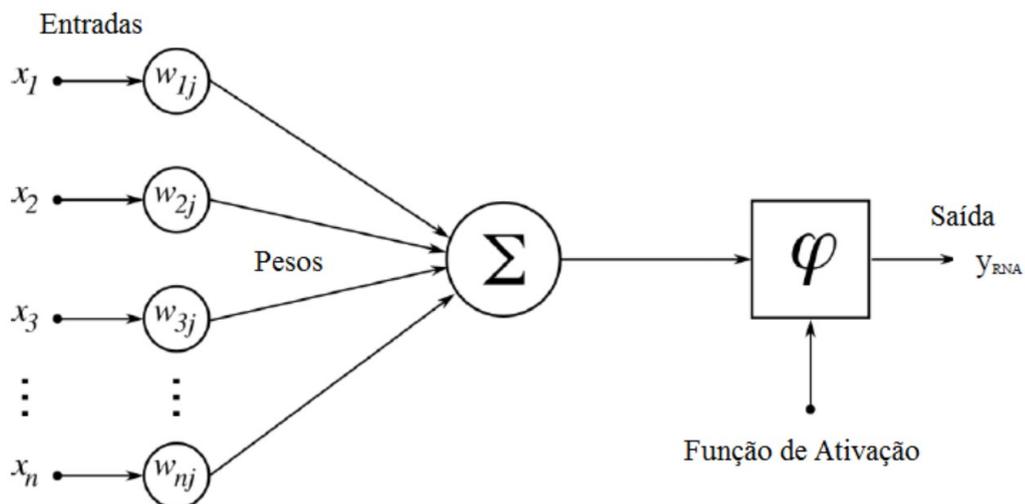
Cada neurônio individualmente pode ser visto como simples e até mesmo lento, se comparado com uma porta lógica moderna baseada em silício, mas, qualquer limitação encontrada pelos sistemas nervosos biológicos é compensada com um número extremamente grande de neurônios e conexões. É estimado que existam aproximadamente 60 trilhões de sinapses entre os 10 bilhões de neurônios no córtex humano. O imenso número de sinapses possíveis e a capacidade do cérebro de modificar conexões existentes geram uma de suas características mais importantes, a plasticidade, que é a capacidade do sistema nervoso em se adaptar aos estímulos recebidos e, conseqüentemente, a habilidade do animal em se adaptar ao ambiente (HAYKIN, 2008).

Estruturado de modo a se assemelhar a uma célula neural biológica, os neurônios artificiais são modelos matemáticos criados para reproduzir as menores

unidades de processamento de sistemas nervosos. Seu funcionamento se inicia com o recebimento de informações que são processados utilizando operações matemáticas simples e funções de ativação, de modo a controlar o formato da saída esperada. Analogamente ao funcionamento do sistema nervoso biológico, esses neurônios são conectados entre eles formando *sinapses* e, assim, gerando as estruturas básicas das Redes Neurais Artificiais (HAYKIN, 2008).

Um modelo de neurônio artificial pode ser visto na Figura 7. Ele funciona multiplicando as entradas ( $x_i$ ) por respectivos pesos ( $w_i$ ), que são, então, somados para se obter um valor de saída ( $y$ ). O treinamento é realizado com objetivo de encontrar os pesos ( $w_i$ ) adequados para um dado problema.

Figura 7 - Estrutura do neurônio artificial



Fonte: Adaptado de Affonso (2010).

### 3.3 Arquiteturas de Redes Neurais Artificiais

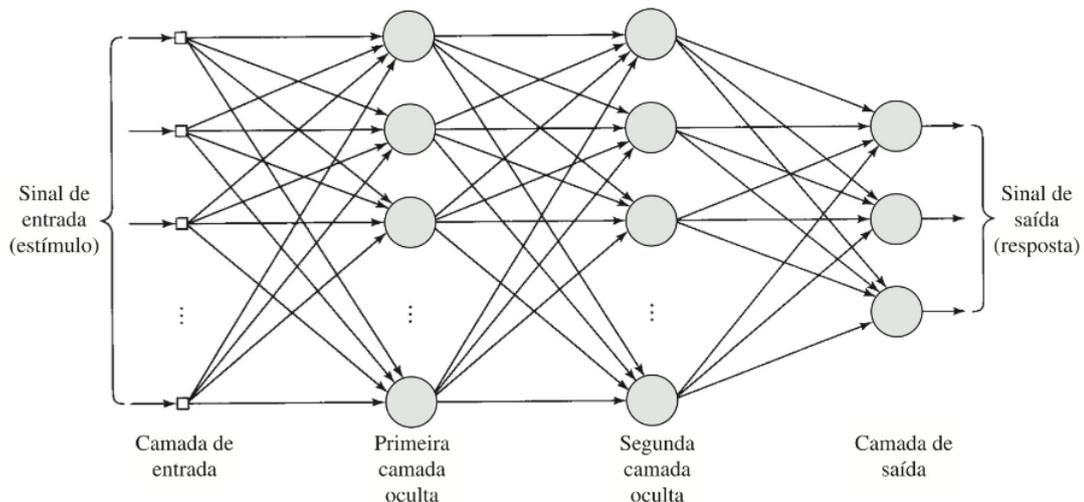
Os neurônios de uma RNA podem ser organizados de diversas maneiras diferentes, a variação nessa estrutura assim como a variação das funções de ativação e do algoritmo de aprendizado pode mudar grandemente a dinâmica de uma RNA. Alguns tipos de RNA conhecidas são:

**FeedForward de camada única:** são modelos de apenas uma camada de neurônios. Nesse caso, os neurônios da camada de saída recebem diretamente os dados da camada de entrada e sua capacidade de processamento é limitada. Os dados, nessa

arquitetura, andam em apenas uma direção, não há reentrada de um dado de saída como dado de entrada.

**Feedforward de múltiplas camadas:** ocorre com a adição de no mínimo mais uma camada ao modelo anterior, chamada de camada oculta, conforme mostrado na Figura 8. Nome que vem do fato dessas camadas escondidas não terem contado direto com os dados de saída ou entrada. A adição dessa camada faz com que as saídas adquiram um teor global, uma vez que os dados processados pelos neurônios se conectam e são ponderados de forma conjunta durante os cálculos da última camada. Esse modelo também não possui reentrada dos dados de saída.

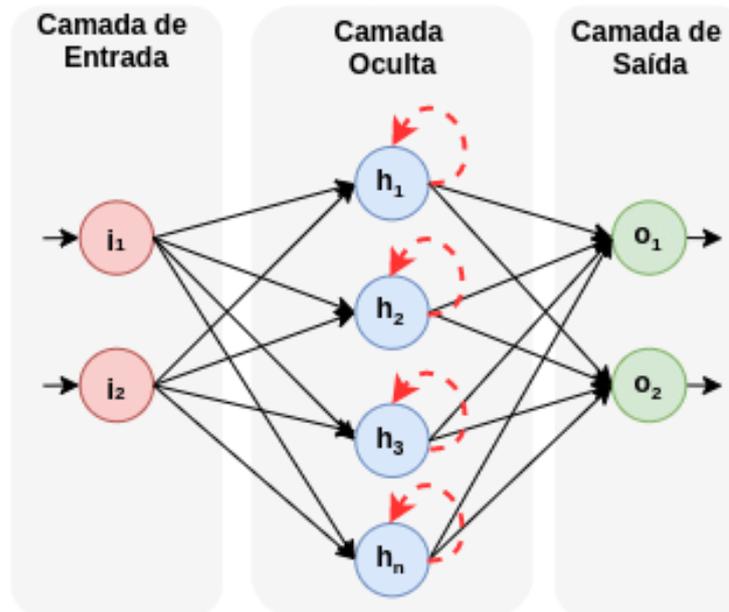
**Figura 8 - Arquitetura de uma RNA Feedforward de múltiplas camadas com duas camadas ocultas**



Fonte: Haykin (2008)

**Rede recorrente:** se diferencia dos demais modelos pela adição de, ao menos uma recorrência ou reentrada, caso em que um dado de saída é adicionado a uma das camadas e reprocessado pela RNA. A Figura 9 exemplifica uma RNA de apenas uma camada oculta, em que os dados de saída são adicionados novamente como dado de entrada. A adição de recorrência em uma RNA pode mudar consideravelmente a dinâmica do aprendizado e, conseqüentemente, o desempenho de uma RNA.

Figura 9 - RNA recorrente



Fonte: Barbosa et al. (2021).

### 3.4 Perceptron de Múltiplas Camadas

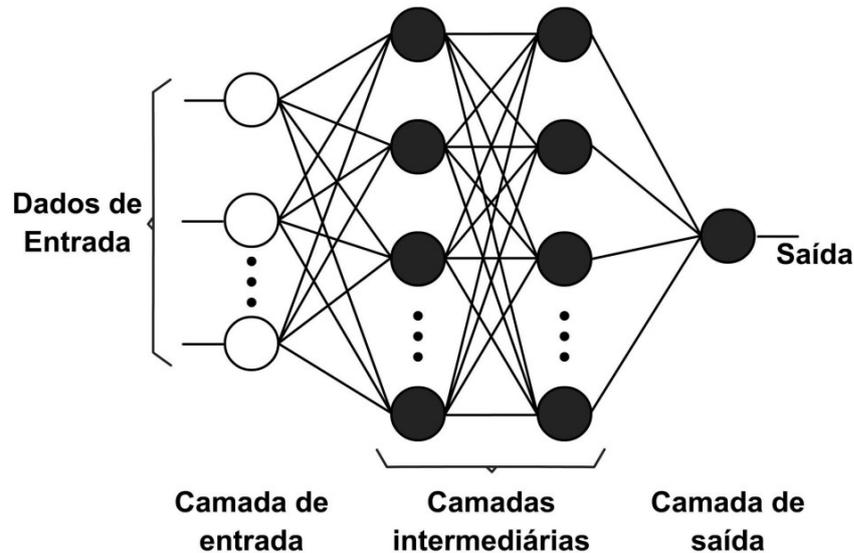
O *perceptron* de Rosenblatt (1958), modelo neural conhecido por ser pioneiro no aprendizado supervisionado, é um modelo simples de rede neural composto por um único neurônio e capaz de reconhecer padrões de problemas linearmente separáveis. Apesar dos avanços para a época, esse tipo de RNA era extremamente limitado. Mas, ao mesmo tempo, não havia sido desenvolvido um método capaz de treinar, de modo eficiente, uma RNA composta de múltiplos neurônios, fato que gerava um grande pessimismo sobre o estudo de RNA da época (HAYKIN 2008).

A popularização do método treinamento supervisionado conhecido como *backpropagation* foi um grande marco para a área. Esse algoritmo, popularizado em 1986 com o lançamento do livro *Parallel Distributed Processing* por Rumelhart, Hinton e Williams (1986). Propunha um método para alteração dos pesos de um neurônio por meio da retropropagação do erro da rede através das diversas camadas. Essa nova aproximação propicia o surgimento do *Perceptron* de Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*), que fica conhecido pela característica não linear das suas soluções, que é provada posteriormente por Cybenko, em 1989, com o teorema da aproximação universal (SIQUEIRA, 2009).

### 3.4.1 Funcionamento de uma MLP

Uma MLP, ilustrada na Figura 10, pode ser definida como uma rede de múltiplas camadas *feedforward* com uma ou mais camadas ocultas ou intermediárias, além das camadas de saída e entrada.

**Figura 10 - Representação gráfica de uma RNA-MLP com duas camadas intermediárias**



Fonte: Fiorin *et al.* (2011).

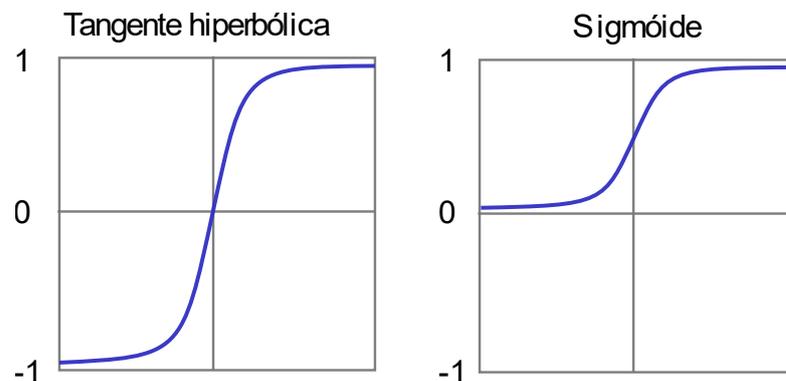
O número de neurônios na camada de entrada e saída são definidos, na maioria dos casos, pelo formato do problema, sendo normalmente iguais, respectivamente, ao número de entradas e saídas da rede. Usualmente, a camada de saída tem apenas um neurônio, cujo valor numérico é a saída esperada da rede.

O número de neurônios nas camadas intermediárias impacta diretamente na qualidade de mapeamento da rede MLP, sendo que um número reduzido de neurônios pode acarretar uma aproximação insuficiente da função problema desejada, gerando erros elevados, enquanto um número excessivo de neurônios pode acarretar outro problema conhecido do treinamento de RNA, o sobre-treinamento ou *overfitting*. Nesse caso, a rede diminui o seu erro relativo ao grupo de treinamento, mas, tem uma menor capacidade de generalização, ou seja, de prever o comportamento de novos dados, por se adaptar excessivamente ao grupo específico de treinamento (HAYKIN, 2008).

Os neurônios em uma MLP variam, a depender da sua camada, um neurônio da camada de entrada recebe como entrada apenas um dos dados aplicados à rede. Um neurônio da camada oculta, normalmente, receberá todos os dados da camada anterior multiplicados pelo seu respectivo peso da conexão. Esses valores são, então,

somados junto com o valor de *bias*, que pode ser considerado uma entrada de valor unitário. A soma dos valores é, então, aplicada a uma função de ativação que pode ter diversas formas. Em redes MLP, geralmente são usadas funções que apresentam imagem no intervalo (0,1) ou (-1,1), como a tangente hiperbólica ou a função sigmóide, mostradas na Figura 11. O valor resultante da função de ativação é a saída do neurônio que é, então, passado à próxima camada. Para esse tipo de função, é importante que as entradas da rede sejam normalizadas dentro do intervalo válido da função. Usualmente, a saída mais simples é dividir cada propriedade pelo maior valor dentro do grupo de testes, mantendo assim, todos os dados entre 1 e -1 (FACELI, 2021).

**Figura 11 - Funções de ativação sigmóide e tangente hiperbólica**



Fonte: Autoria Própria (2023).

A formulação para o cálculo da saída de uma rede MLP, com uma camada, três entradas e uma saída, é mostrada pela Equação (20):

$$Y(x_1, x_2, x_3) = f \left\langle \sum_{k=1}^n \left\{ \sum \varphi \left[ \sum_{j=1}^n \left( \sum_{i=1}^3 x_i w_{ij} \right) + w_{eb} \right] w_{sj} \right\} + w_{ob} \right\rangle, \quad (20)$$

em que,  $f(x)$  é a função da camada de saída;  $\varphi(x)$  é a função da camada oculta;  $n$  é o número de neurônios na camada oculta;  $w_{ij}$  é o peso para a entrada  $i$  e para o neurônio da camada oculta  $j$ ;  $w_{sj}$  é o peso para a saída  $s$  para o neurônio da camada oculta  $j$ ;  $w_{eb}$  é a *bias* para a camada de entrada;  $w_{ob}$  é a *bias* para a camada oculta;  $Y(x_1, x_2, x_3)$  é a saída da rede.

### 3.4.2 Backpropagation

Diversos algoritmos foram desenvolvidos para o treinamento de MLP, dentre eles, o mais utilizado e conhecido é o método de retropropagação de erro, que se baseia na regra de aprendizagem por correção de erro, que consiste em duas fases:

**Propagação:** dados de entrada são aplicados a entrada da rede, se propagando pelas próximas camadas e finalmente produzindo um conjunto de saídas. Nesse passo não há modificação dos pesos.

**Retropropagação:** a resposta conseguida no passo de propagação é utilizada junto com o dado de saída conhecido, para produzir um sinal de erro, que é então retropropagado pela rede e utilizado para modificar os pesos.

De acordo com Haykin (2008), o passo de propagação da saída de cada neurônio pode ser representado pela Equação (21):

$$y_j(n) = \varphi[v_j(n)], \quad (21)$$

sendo que,  $\varphi$  é a função de ativação e  $v_j(n)$  é a somatória das saídas da camada anterior multiplicadas pelos respectivos pesos e pode ser expressar pela Equação (22):

$$y_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n), \quad (22)$$

sendo que,  $w_{ji}$  é o peso que conecta a saída de índice  $i$  a entrada de índice  $j$ .  $y_i(n)$  é a saída do neurônio  $i$  e  $m$  é o número de neurônio da camada anterior. Para a primeira camada oculta o valor de  $y_i(n)$  é o mesmo da entrada  $x_i(n)$ .

Durante o *backpropagation* os valores dos pesos  $w_{ji}(n)$  são modificados de modo supervisionado (com um grupo de dados já conhecidos como referência). Para cada conexão o novo peso pode ser encontrado aplicando uma correção  $\Delta w$  ao peso atual com objetivo de minimizar o erro (Equação (23)):

$$w(n+1) = w(n) + \Delta w(n). \quad (23)$$

O erro quadrático médio em uma RNA pode ser representado como uma função, assim, o objetivo da aplicação do *backpropagation* é encontrar uma região de menor valor nessa função. Como a direção do gradiente de uma função é também a direção de maior crescimento, a direção negativa do gradiente representa a direção que a energia do erro decresce mais rapidamente, com isto,  $\Delta w(n)$  é conseguido pela derivada parcial do erro em função do peso atual. O sinal negativo representa a diminuição na função erro.

$$\Delta w(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)}. \quad (24)$$

A resolução da Equação (24) depende da camada do peso a ser modificado. Para a camada de saída a solução dessa equação é dada pela Equação (25):

$$\delta_j(n) = \varphi'[v_j(n)] e_j(n), \quad (25)$$

sendo que,  $\varphi'$  é a derivada da função de ativação e o sinal de erro  $e_j$  é dado pela diferença entre o resultado esperado e o encontrado através da Equação (26):

$$e_j = d_j - y_j. \quad (26)$$

Para uma camada oculta, a solução é dada pela Equação (27):

$$\delta_j(n) = \varphi'[v_j(n)] \sum_k \delta_k(n) w_{kj}(n), \quad (27)$$

sendo que o índice  $k$  representa as conexões de saída do neurônio  $j$ .

### 3.4.3 Treinamento da MLP e validação cruzada

Para que uma Rede MLP possa ser treinada é necessário que estejam definidos os números de neurônios na sua camada oculta além do número de camadas ocultas que, mesmo que não tão comum, também pode variar. Os valores dessas variáveis não são facilmente encontrados sem conhecimento profundo sobre

as propriedades do problema. Muitas vezes mesmo com o devido estudo de problemas semelhantes o número ideal pode não ser encontrado, sendo necessária uma avaliação de muitas opções e dos melhores resultados.

Durante a busca pelos melhores parâmetros, o algoritmo é aplicado repetidamente para diferentes variações desses e é, em cada configuração aplicado iterativamente até ser alcançado um critério de parada, que pode ser definido como um número máximo de iterações a serem realizadas ou um valor de erro a ser alcançado.

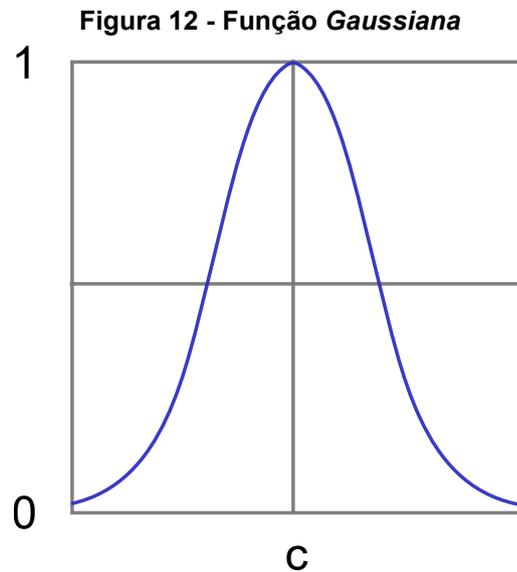
Também é importante notar que utilizar como critério o erro encontrado ao se avaliar o comportamento da rede em relação aos dados utilizados em seu treinamento pode não ser a melhor escolha, uma vez que existe a possibilidade do modelo se ajustar excessivamente ao conjunto de treinamento e conseqüentemente, apresentar um valor de erro que não representa a real capacidade de generalização dessa configuração. A opção escolhida para contornar esse problema, usualmente, é a utilização de uma parte do conjunto de dados, nomeado conjunto de validação, para avaliar o comportamento da rede. Como esse novo conjunto não é utilizado para treinar a rede, é possível avaliar, paralelamente ao treinamento, a capacidade de generalização da rede (HAYKIN, 2008).

### **3.5 Rede Função de Base radial**

Uma Rede Função de Base Radial ou RBF (do inglês, *Radial-Basis Function*), é basicamente uma rede neural com três camadas. Enquanto as suas camadas de entrada e saída são análogas às RNA do tipo MLP, sua única camada oculta é responsável por aplicar uma transformação não linear no espaço de entrada para um espaço de mais alta dimensionalidade.

Essa estratégia é justificada seguindo o Teorema de *Cover* (1965) sobre a separabilidade de padrões, que mostra, em seus resultados, que um problema de classificação disposto em um espaço de mais alta dimensionalidade tem uma maior probabilidade de ser linearmente separável. Assim, em uma RBF o problema é inicialmente não linearizado em um espaço de alta dimensionalidade e, na sequência, é transformado linearmente pela camada de saída. Também é importante ressaltar que a capacidade de aproximação da rede está diretamente ligada com a dimensionalidade do espaço criado pela camada oculta (HAYKIN, 2008).

O nome dado a essa Rede Neural Artificial se dá pelo tipo das funções não linear de ativação, usualmente uma Função *Gaussiana* (Figura 12), utilizada nesse tipo de RNA que resultam em fronteiras de decisão no formato elíptica quando em um plano bidimensional.



A formulação para o cálculo da saída de uma rede RBF, com três entradas, uma saída e uma camada oculta, é expressa pela Equação (28):

$$Y(x_1, x_2, x_3) = f \left\langle \sum_{k=1}^{n-1} \left\{ \sum_{j=0}^{n-1} \left[ \sum_{i=0}^2 x_i \right] + w_{eb} \right\} w_{sj} \right\} + w_{ob} \right\rangle, \quad (28)$$

sendo que,  $f(x)$  é a função de ativação da camada de saída,  $\varphi(x)$  é a função de ativação da camada de saída,  $n$  é o número de neurônios na camada oculta,  $w_{sj}$  é o peso para a saída  $s$  para o neurônio da camada oculta  $j$ ,  $w_{eb}$  é a *bias* para a camada de entrada,  $w_{ob}$  é a *bias* para a camada oculta e  $Y(x_1, x_2, x_3)$  é a saída da rede.

### 3.5.1 Treinamento de uma RBF

O treinamento de uma RBF exige um tratamento diferente para as camadas ocultas e de saída. Durante a primeira parte é necessário encontrar as propriedades de cada neurônio da camada oculta, que utiliza uma Função *Gaussiana* como função de ativação.

A Função *Gaussiana* pode ser escrita como:

$$\varphi(x) = ae^{\frac{\|x-c_j\|_2}{2\sigma^2}} \quad (29)$$

em que:

$$\|x - c_j\|_2 = \sqrt{\sum_{i=0}^3 (x_i - c_i)^2} \quad (30)$$

sendo que,  $c_i$  é o centro mais próximo da entrada  $i$  definido na fase de treino.

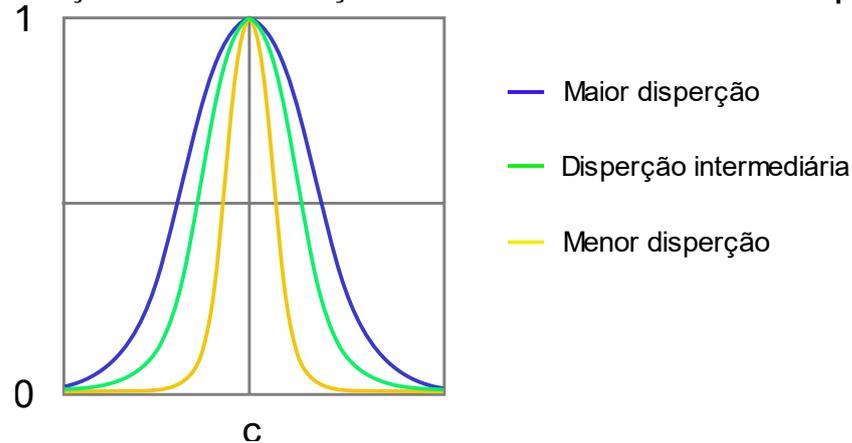
Utilizando a função mostrada na Figura 12 pode se visualizar o parâmetro “ $a$ ” como a altura do pico da função (1 no caso da Figura 13), o parâmetro  $c$  representa o valor do eixo  $x$  no pico ou no centro da *Gaussiana*, enquanto  $\sigma$  é dado pelo desvio padrão. As posições dos centros usualmente são encontradas utilizando algoritmos como o PSO e o *K-means*, enquanto as dispersões, podem também ser diferentes para cada centroide, mas usualmente são dadas por um valor fixo e igual que é encontrado pela função:

$$\sigma = \frac{d_{\max}}{\sqrt{2m}}, \quad (31)$$

sendo que,  $m$  é o número de centros utilizados. No caso da RBF é dado pela quantidade de neurônios na camada oculta e  $d_{\max}$  é a distância máxima entre dois centros.

Os valores de dispersão modificam o formato da *Gaussiana* (Figura 13) e utilizando a Equação (31), pode ser evitada uma forma com base excessivamente grande ou pequena.

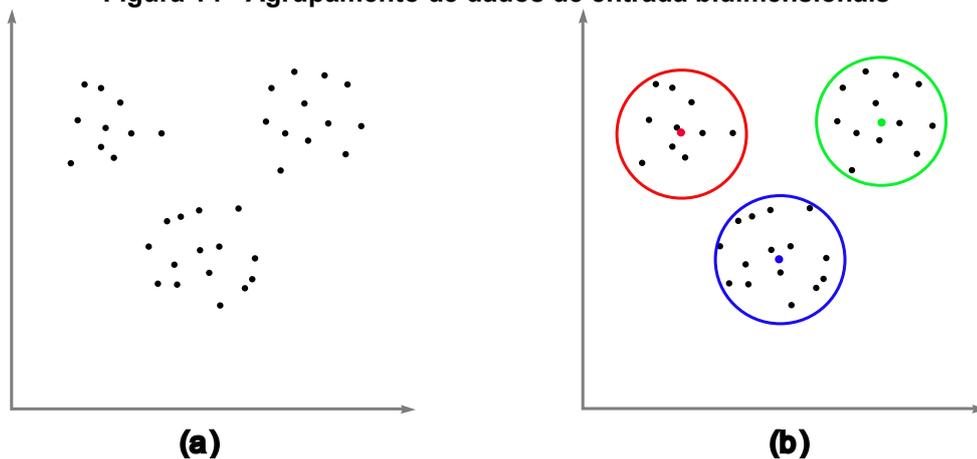
Figura 13 - Variação da forma da Função *Gaussiana* com diferentes desvios padrão



Fonte: Autoria Própria (2023)

O treinamento da camada oculta de uma RBF é feito de modo não supervisionado, ou seja, utiliza apenas os dados de entrada, sem relação com os respectivos dados de saída. Essa parte do treinamento tem como objetivo encontrar agrupamento desses dados como no exemplo mostrado na Figura 14(a), que mostra um grupo de dados bidimensionais representados em um plano. O posicionamento das Funções *Gaussianas* realizados na primeira parte do treinamento são feitos de modo aceitável para separar de modo aceitável os agrupamentos encontrados, como visto na Figura 14(b) (HAYKIN, 2008).

Figura 14 - Agrupamento de dados de entrada bidimensionais



Fonte: Autoria Própria (2023)

Encontrados os raios das Funções de *Gauss*, podem então ser aplicados algoritmos como PSO e *k-means* iterativamente, para que sejam encontrados os centroides, iniciados aleatoriamente, para cada neurônio da camada oculta. Terminada a primeira etapa do treinamento, deve-se então, encontrar os pesos de entrada para a camada de saída, que podem ser obtidos de maneira análoga à MLP ou utilizando o Método da Pseudo Inversa de *Moore-Penrose* (Seção 3.6.1).

### 3.5.2 *k-means*

Alguns métodos de clusterização podem ser utilizados para resolver o problema da localização dos centros da *Gaussiana*. Dentre eles, o mais conhecido e utilizado é chamado *k-means Clustering* ou apenas *k-means*. Esse é um método proposto por MacQuenn (1967) de agrupamento não supervisionado que avalia o posicionamento dos *clusters* minimizando a raiz da distância Euclidiana (Equação (32)) dos pontos associados a cada centro.

$$d(x, c) = \sqrt{\sum_{i=1}^n (x_i - c_i)^2}, \quad (32)$$

sendo  $x$  e  $c$  dois pontos no espaço compostos pelas coordenadas  $x_1, x_2, x_3, \dots, x_n$  e  $c_1, c_2, c_3, \dots, c_n$ .

A utilização do *k-means* inicia com a geração aleatória dos centroides, em um número fixo preestabelecido. Depois disso, cada grupo de dados é associado ao centroide mais próximo e, então, se calcula uma nova posição para cada centroide calculando-se a média de todos os valores relacionados a ele. Esse processo é repetido até que se atinja um critério de parada. Esse algoritmo, apesar de apresentar algumas desvantagens, ainda é largamente utilizado por conta da sua facilidade de implementação e a rápida convergência (DA SILVA; SPATTI; FLAUZINO, 2010).

O *k-means* é extremamente dependente da condição inicial, encontrada aleatoriamente, por isso, cada novo teste, mesmo utilizando os mesmos dados, pode resultar em resultados divergentes, o que afeta diretamente o resultado da rede RBF.

#### 3.5.2.1 Otimização por Enxame de Partículas

A otimização por Enxame de partículas (PSO, do inglês *Particle Swarm Optimization*) é uma técnica para otimização de funções baseado no comportamento social de diversas espécies, dentre elas peixes, pássaros e até mesmo os seres humanos. O seu desenvolvimento se baseou na ideia de que a troca de informações dentro de uma população oferece uma grande vantagem evolutiva (FACELI, 2021).

No algoritmo PSO, são geradas diversas partículas que representam possíveis soluções. Esses agentes se movimentam pelo espaço da função, sendo capazes de armazenar e também de transmitir informações para outras partículas, resultando

assim, em uma combinação de aprendizado local (cognitiva) e global (social). Com isso, o algoritmo é capaz de procurar o resultado ótimo se utilizando das melhores informações conseguidas (FACELI, 2021). O funcionamento do PSO ocorre por:

1. Inicialização das partículas aleatoriamente no problema com velocidades aleatórias;
2. Cada partícula calcula o seu *fitness* ou a qualidade da solução encontrada;
3. Cada partícula calcula se o *fitness* atual é o seu melhor já encontrado pessoalmente;
4. Cada partícula calcula se o *fitness* atual é o melhor já encontrado globalmente;
5. É verificado se um critério de parada foi atingido. Caso seja, o algoritmo termina;
6. A velocidade de cada partícula é atualizada;
7. Os passos de 2 a 6 são repetidos até que um critério de parada seja atingido.

O cálculo da velocidade da partícula (Equação (33)) depende de alguns parâmetros importantes no funcionamento do PSO, entre eles está a *importância* que o algoritmo deve dar ao melhor valor global (*gbest*), ao melhor valor pessoal (*pbest*) e à própria inércia da partícula durante a busca. O número de agentes também tem grande influência, uma vez que o aumento desse gera mais velocidade durante a busca, em troca de maior gasto computacional (FACELI, 2021).

$$v_{i+1} = wv_i + C_1r_1(pbest_i - x_i) + C_2r_2(gbest_i - x_i), \quad (33)$$

sendo que,  $v$  é a velocidade,  $w$  é o peso da inércia da partícula,  $C_1$  e  $C_2$  são os coeficientes de aprendizado de *pbest* e *gbest*, respectivamente,  $r_1$  e  $r_2$  representam dois valores aleatórios uniformemente distribuídos e  $x$  é a posição atual da partícula.

O PSO pode ser utilizado no treinamento de diversas Redes Neurais Artificiais e, assim como o *k-means*, é uma opção para a primeira parte do treinamento da Rede RBF, onde são encontrados os centros das *Gaussianas*. Também é importante ressaltar que o treinamento utilizando apenas o PSO pode trazer desvantagens, como o tempo de processamento, que pode se tornar impeditivo a depender do tamanho do problema (FACELI, 2021).

### 3.6 Máquinas de Aprendizado Extremo

A Máquina de Aprendizado Extremo (ELM, do inglês *Extreme Learning Machine*) é um algoritmo de aprendizado proposto por Hung *et al.* (2004) para Redes *Feedforward* com apenas uma camada oculta que utiliza pesos aleatórios constantes na camada intermediária e um método analítico na determinação dos pesos da camada de saída, não precisando dos métodos iterativos baseados no gradiente descendente. As vantagens da utilização desse método são a sua velocidade de treinamento que, de acordo com Huag *et al.* (2006) pode ser milhares de vezes mais rápido que o treinamento via *Backpropagation*, além de contornar diversos outros problemas vistos anteriormente como a convergência para mínimos locais e o *overfitting*.

#### 3.6.1 Inversa generalizada de Moore-Penrose

Classicamente o conceito de matriz inversa diz que se uma matriz  $A$  tem uma matriz inversa  $A^{-1}$  essa matriz deve necessariamente ser quadrada e possuir um determinante diferente de zero, ou ainda, deve possuir linhas e colunas linearmente independentes. Muitos problemas envolvendo matrizes aproveitam-se das características únicas dessas matrizes inversas para gerar soluções para equações do tipo  $Ax = b$ . Caso a inversa exista nesse caso a solução existe e pode ser dada por  $x = A^{-1} b$ . Do mesmo modo existem diversas situações em que os sistemas apresentam soluções associadas, mas, geram uma matriz não invertível ou não quadrada impossibilitando a solução utilizando o método mais simples. Para solucionar problemas desse tipo é necessária outra abordagem que pode envolver o uso de inversas generalizada (DUARTE, 1996).

O trabalho de *E. H. Moore* em 1920 investigou a ideia de uma matriz com propriedades de inversa para matrizes não quadradas. Anos depois, a sua ideia foi formalizada por *R. Penrose* e denominada Inversa Generalizada de *Moore-Penrose* ou pseudo-inversa (SOUZA, 1988). Essa matriz é definida como a matriz  $G$  que satisfaz as seguintes condições (Equações (34) a (37)):

$$A G A = A , \tag{34}$$

$$G A G = G , \tag{35}$$

$$A G = (G A)^t, \quad (36)$$

$$G A = (A G)^t. \quad (37)$$

E pode ser definida pela Equação (38):

$$A^\dagger = (A^* A)^{-1} A^*, \quad (38)$$

sendo que,  $A^\dagger$  é a pseudo-inversa e  $A^*$  é a matriz transposta ou a matriz adjunta de  $A$ .

### 3.6.2 Treinamento de Máquinas de Aprendizado Extremo

Inicialmente é gerado uma Matriz  $\mathbf{W}$  de pesos aleatórios da camada oculta, essa matriz, que não é modificada durante o treinamento, é multiplicada por cada conjunto de dados  $\mathbf{X}$  (adicionado de um valor numérico chamado *bias* geralmente de valor 1) para gerar uma Matriz  $\mathbf{J}$  contendo os valores calculados que são então aplicados a função de ativação gerando a Matriz  $\mathbf{H}$ .

$$\mathbf{X} = \begin{bmatrix} x_1^1 & \cdots & x_m^1 & 1 \\ \vdots & \ddots & \vdots & \vdots \\ x_1^i & \cdots & x_m^i & 1 \end{bmatrix}, \quad (39)$$

$$\mathbf{W} = \begin{bmatrix} w_{11} & \cdots & w_{1d} \\ \vdots & \ddots & \vdots \\ w_{m1} & \cdots & w_{md} \\ b_1 & \cdots & b_d \end{bmatrix}, \quad (40)$$

$$\mathbf{J} = \mathbf{X} \times \mathbf{W}, \quad (41)$$

$$\mathbf{H} = \begin{bmatrix} f(J_1^1) & \cdots & f(J_1^{d+1}) \\ \vdots & \ddots & \vdots \\ f(J_{i+1}^1) & \cdots & f(J_{i+1}^{d+1}) \end{bmatrix}, \quad (42)$$

sendo que o índice  $i$  representa o número de grupos de dados de treinamento,  $m$  representa o número de entradas da rede,  $d$  é a quantidade de neurônios na camada oculta e  $b$  é o *bias* de cada neurônio.

Tendo o valor da Matriz  $\mathbf{H}$ , a formulação para o cálculo da saída de uma Rede ELM, é dada pela Equação (43):

$$\mathbf{Y} = \mathbf{H}\boldsymbol{\beta}, \quad (43)$$

sendo que,  $\mathbf{Y}$  é o vetor de saídas desejadas e pode ser expresso pela Equação (44):

$$\mathbf{Y} = [y_1, \dots, y_n], \quad (44)$$

e que  $\boldsymbol{\beta}$  é a matriz de pesos que guarda as informações de treinamento, e pode ser obtida solucionando o sistema da Equação (43):

$$\boldsymbol{\beta} = \mathbf{H}^\dagger \mathbf{Y}, \quad (45)$$

sendo que,  $\mathbf{H}^\dagger$  é a inversa generalizada de *Moore-Penrose* da Matriz  $\mathbf{H}$ .

Assim, a Equação (43) torna-se:

$$\mathbf{Y} = \mathbf{H}\mathbf{H}^\dagger \mathbf{Y}. \quad (46)$$

## 4 ESTADO DA ARTE

Neste capítulo são apresentados trabalhos relacionados a utilização de Redes Neurais Artificiais para a avaliação e simulação de tubos de calor e/ou termossifões, além de outros trocadores de calor.

Hakeem *et al.* (2008) utilizaram Redes Neurais Artificiais para a predição de perfis de temperatura em um *reboiler* que utiliza termossifões. O aparato experimental foi utilizado por Nihaluddin (1991), Kamil *et al.* (2005) e Kamil e Ali (1995). Os dados experimentais mostram uma alta dependência entre fluxo de calor e razão de preenchimento. Foram coletados para os quatro níveis de razão de preenchimento do sistema: 100%, 75%, 50% e 30%. O problema foi separado em dois grupos: a) predição dos perfis de temperatura com fluxo de calor como entrada e interpolação e extrapolação de cada razão de preenchimento particular e; b) treinamento da rede para o grupo completo de dados com fluxo de calor como entrada e distância, razão de preenchimento e temperatura como saídas. Foi utilizada uma Rede Neural *Feedforward* treinada pelo Algoritmo *Backpropagation*. Os resultados mostraram boa capacidade de predição das temperaturas quando comparada com os resultados experimentais.

Kalogirou *et al.* (1999) realizaram um estudo visando avaliar a utilização de uma RNA como uma ferramenta para estimar o desempenho de um aquecedor de água solar. Como parâmetro a ser avaliado foi utilizado a quantidade de energia solar térmica útil extraída e armazenada. O sistema de aquecimento consiste em um coletor solar de placa plana de área total de 2,08m<sup>2</sup> e um tanque horizontal de água quente com capacidade de armazenamento de até 200L. O painel foi composto por 16 tubos de subida com 9.5mm de diâmetro cada. Foram utilizados quatro sistemas de coletores solares, três que utilizavam termossifões abertos e um com termossifão fechado, aquecendo tanques de água entre 125L e 200L. Foram testadas diferentes arquiteturas de redes neurais com o objetivo de encontrar a que se comportava melhor para o problema dado. A configuração com os melhores resultados é uma Rede MLP com sete entradas, duas saídas e vinte e quatro neurônios na camada oculta. A função de ativação utilizada na camada oculta e de saída foi a função sigmoide. O algoritmo de treinamento utilizado foi o *Backpropagation*. Os resultados mostraram que uma vez treinada, a RNA pode gerar resultados com diferenças absolutas entre os valores

calculados e medidos entre  $-2,2^{\circ}\text{C}$  e  $2,0^{\circ}\text{C}$  e valores de coeficiente de determinação ( $R^2$ ) variando entre 0,98 e 0,99.

Também foi estudado por Kalogirou *et al.* (2000) a aplicabilidade de uma RNA, na predição dos resultados de um sistema de aquecimento de água utilizando termossifões abertos e fechados por longos períodos. Foram realizadas a avaliação de várias Redes Neurais Artificiais com intuito de prever a quantidade de energia solar acumulada em tanques de água com volume variando entre 100L e 200L. Foram testadas RNA com arquiteturas do tipo MLP, RBF e combinações variando o número de camadas e neurônios para cada modelo. Duas RNA foram selecionadas e utilizadas na simulação do sistema, estas constituídas por 15 e 16 neurônios na camada de entrada, e por 3 blocos com 8 neurônios e diferentes função de ativação na camada oculta. A comparação entre os resultados experimentais e calculados obteve um coeficiente de determinação ( $R^2$ ) de mais de 0,99 para os dois casos demonstrando a assertividade das RNA.

Na pesquisa de Chen *et al.* (2010), foi realizado um estudo sobre a aplicabilidade de uma MLP na predição do fluxo crítico de calor de um termossifão aberto concêntrico. Foram realizados testes com três fluidos de trabalho diferentes, R113, R22 e água. Cada um deles a diferentes pressões de trabalho e com diferentes parâmetros geométricos, como diâmetro interno e externo dos tubos interno e externo, além do comprimento. O banco de dados foi formado por 804 dados experimentais selecionados de experimentos de Mitsutake *et al.* (1997) e Islam *et al.* (1998, 2005). A rede utilizada foi a MLP e os melhores parâmetros foram encontrados por tentativa e erro, resultando em 4 neurônios na camada de entrada, 7 na camada oculta e 1 na camada de saída. Foi empregada uma função de ativação do tipo S (sigmoide ou hiperbólica). Os resultados mostram que a RNA é adequada para prever o comportamento do fluxo crítico de calor com Erro Quadrático Médio (RMS), menor que 18%.

Shanbedi *et al.* (2013) conduziram um experimento utilizando Redes Neurais Artificiais para avaliar o desempenho de um termossifão bifásico fechado que tinham como fluidos de trabalho dois tipos de nanofluidos. Foi utilizado como fluido de trabalho água com a adição de nanotubo de carbono de parede múltipla. As dimensões do termossifão utilizado foram de 0,16m para o evaporador, 0,10m para o condensador e 0,09m para a seção adiabática. As potências utilizadas foram de 10W, 60W, 90W, 120W e 150W. A RNA utilizada foi uma MLP, o número de neurônios na

camada oculta determinada por tentativa e erro resultando em 24 neurônios. A camada de saída possui 2 neurônios enquanto a camada de entrada foi composta por 3 neurônios. A rede foi treinada utilizando o Algoritmo de *Levenberg–Marquardt*. Para a realização do estudo, foram utilizados como dados de entrada os parâmetros de títulos do fluido de trabalho e potências dissipadas no termossifão além do comprimento do termossifão e como dado de saída foi calculada a distribuição de temperatura esperada. Foi concluído que a RNA se mostrou eficiente para a predição do comportamento do termossifão, com resultados para  $R^2$  acima de 0,99, RMSE, Desvio Quadrático Médio, de 0,334 entre outros parâmetros que mostram uma excelente relação entre os resultados experimentais e simulados.

Salehi *et al.* (2011) utilizaram uma RNA para estimar a eficiência térmica e a resistência de um termossifão fechado em um campo magnético, usando nanofluidos de prata de 10nm. Foram realizados experimentos com diferentes quantidades de prata na dissolvida em água. O sistema foi aquecido utilizando uma fita resistiva com potência nominal de 250W. Ímãs permanentes foram posicionados na seção do evaporador. Um total de 87 experimentos foram realizados e os dados obtidos foram utilizados para o treinamento da RNA. A rede utilizada foi uma MLP com método de treinamento sendo o Algoritmo *Backpropagation*. O número de neurônios na camada oculta foi selecionado utilizando o Algoritmo Genético. A intensidade do campo magnético, a fração volumétrica de nanofluido na água e a potência dissipada foram usados como parâmetros de entrada. Os resultados foram comparados com os dados experimentais e mostraram boa correlação para eficiência e resistência.

A influência de diversos parâmetros no desempenho de um termossifão vertical com aletas, utilizando água como fluido de trabalho, foi investigada, usando uma Rede Neural Artificial, por Rajab *et al.* (2021). Foi utilizado para o experimento um termossifão de cobre com diâmetro interno de 6,75mm espessura de 1mm e comprimento de 600mm. O evaporador foi aquecido por uma fita resistiva de potência máxima igual a 250W. O condensador possui 50 aletas anulares de 1mm de espessura e raio de 400mm. Foram testados diferentes fluidos de trabalhos sendo eles metanol puro, água pura, e diferentes razões de mistura metanol-água (40%, 60% e 80%). A potência utilizada foi variada entre 100W e 250W. A rede neural utilizada foi uma MLP treinada pelo Algoritmo *Backpropagation* utilizando também o Algoritmo de *Levenberg-Marquardt*. Foram utilizados como entradas o fluido de trabalho, razão da mistura e a potência dissipada, resultando em 3 neurônios na camada oculta

enquanto o dado de saída utilizado para avaliar a eficiência do termossifão foi a resistência térmica apresentada pelo termossifão. O algoritmo foi testado para vários números de neurônios na camada oculta. O estudo mostrou que a RNA tem grande potencial para prever mesmo as complexas características de um termossifão, resultando em um Desvio Quadrático Médio (RMSE) de 0,098% e Erro Quadrático Médio (RMS) de 0,097%, mostrando alta concordância entre os dados experimentais e simulados.

A bibliografia apresentada, traz poucos trabalhos sobre a utilização de RNA no desenvolvimento de termossifões e tubos de calor, uma vez que existe uma falta de trabalhos desse tipo na literatura. Além disso, os estudos apresentados mostram alguns problemas, como a baixa visibilidade do algoritmo utilizado, pouca explicação das métricas de erro avaliadas e seu significado, além de pouca variação dos algoritmos utilizados. Em contrapartida, é possível também perceber que, alguns trabalhos mostram resultados positivos sobre a utilização das RNA no projeto de tubos de calor e termossifões e outros tipos de trocadores de calor.

Nesse contexto, o presente trabalho busca gerar resultados capazes de diminuir a lacuna mostrada na literatura e confirmar a capacidade das Redes Neurais Artificiais em auxiliar o projeto de termossifões e tubos de calor, além de servir como ponto de partida para outros trabalhos na área.

## 5 BANCO DE DADOS

Neste capítulo, são descritos os trabalhos dos quais se originaram os dados utilizados no treinamento das RNA desta Dissertação de Mestrado, bem como as características dos termossifões experimentados e os critérios para a composição do banco de dados.

Os experimentos realizados para a obtenção dos dados experimentais foram executados no Laboratório de Controle Térmico (LabCT) vinculado ao Programa de Pós-Graduação *Multicampi* em Engenharia Mecânica (PPGEM) da Universidade Tecnológica Federal do Paraná (UTFPR)/*Campus* Ponta Grossa. As investigações envolveram termossifões e tubos de calor contendo água destilada como fluido de trabalho com suas principais características mostradas no Quadro 2.

Os dados utilizados foram divididos em dois grupos. Um grupo composto por dados referentes a testes experimentais realizados em termossifões de cobre obtidos por Aguiar (2016) e um segundo grupo composto de tubos de calor de cobre, com dados obtidos por Krambeck (2016) – tela metálica, Krambeck (2018) – pó de cobre sinterizado e Nishida (2016) – ranhuras axiais.

**Quadro 2 - Características geométricas dos termossifões e tubos de calor utilizados**

<b>Característica do termossifão</b>	<b>Valor</b>
Diâmetro interno [mm]	7,75
Diâmetro externo [mm]	9,45
Comprimento do evaporador [mm]	80
Comprimento da seção adiabática [mm]	20
Comprimento do condensador [mm]	100

**Fonte: A autoria Própria (2023)**

### 5.1 Termossifões

A investigação experimental realizada por Aguiar (2016) resultou em um banco de dados sobre o comportamento de termossifões em diferentes condições. Para a execução do experimento foi utilizado o aparato como o mostrado na Fotografia 1, composto de uma fonte *Keysight*<sup>TM</sup> U8002A, um sistema de aquisição de dados *Keysight*<sup>TM</sup> 34970A com um multiplexador de 20 canais, um *nobreak* *NHS*<sup>TM</sup>, um ventilador *Ultrar*<sup>TM</sup>, suporte universal e um microcomputador *Dell*<sup>TM</sup>.

Fotografia 1 - Aparato experimental

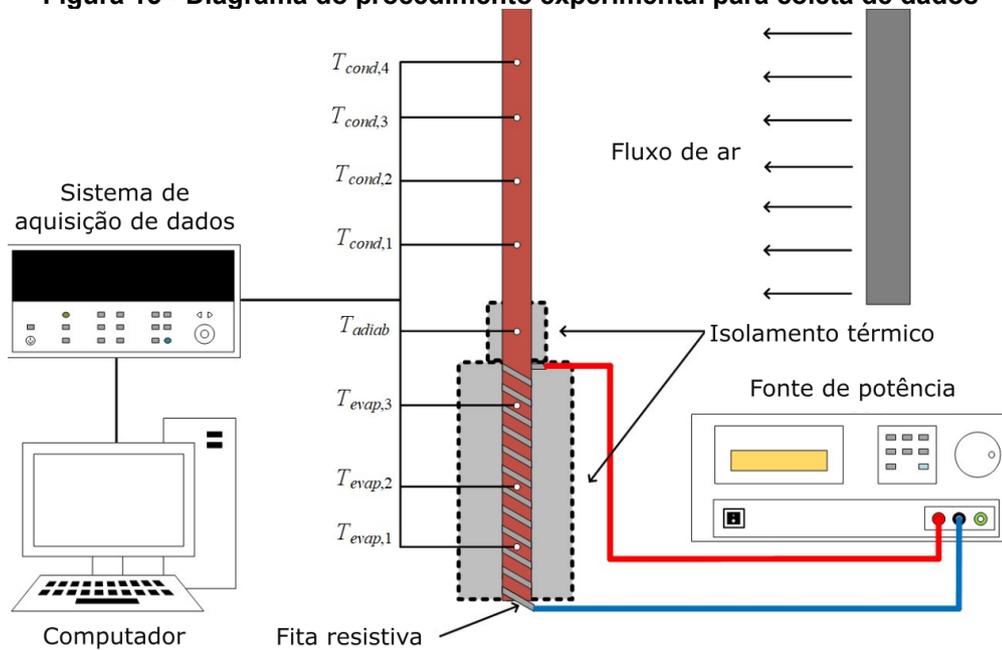


Fonte: Aguiar (2016)

### 5.1.1 Procedimento experimental para a aquisição de dados

Durante a realização dos experimentos a temperatura foi mantida a aproximadamente 20°C. Para o aquecimento do evaporador, calor foi gerado a partir de Efeito *Joule* utilizando uma fita resistiva, enquanto convecção forçada, gerada pelo ventilador, foi utilizado para o resfriamento. Diversos termopares, representados por  $T_{cond}$ ,  $T_{adiab}$  e  $T_{evap}$ , foram utilizados para a obtenção da temperatura em vários pontos durante a operação. O diagrama do experimento pode ser visto na Figura 15.

Figura 15 - Diagrama do procedimento experimental para coleta de dados



Fonte: Machado et al. (2023)

Os testes foram realizados com potências dissipadas de 5W a 45W com passos de 5W, evitando a temperatura crítica de 150°C. Cada potência foi mantida até que o sistema atingisse estado quase estacionário para que então fossem tomadas as temperaturas. Foram também utilizadas duas inclinações de trabalho dos termossifões: 45° e 90° com a horizontal.

#### 5.1.1.1 Dados utilizados

Para a o treinamento das RNA utilizadas nesse trabalho foram obtidos um total de 47 dados que podem ser vistos no Anexo A. A Tabela 1 compila as informações referentes aos dados experimentais.

**Tabela 1 - Informações sobre os parâmetros utilizados por Aguiar (2016)**

<b>Inclinação de Trabalho [°]</b>	90 e 45
<b>Razão de Preenchimento [%]</b>	20, 40, 60, 80 e 100
<b>Potência Dissipada [W]</b>	5, 10, 15, 20, 25, 30, 35, 40 e 45

**Fonte: Autoria Própria (2023)**

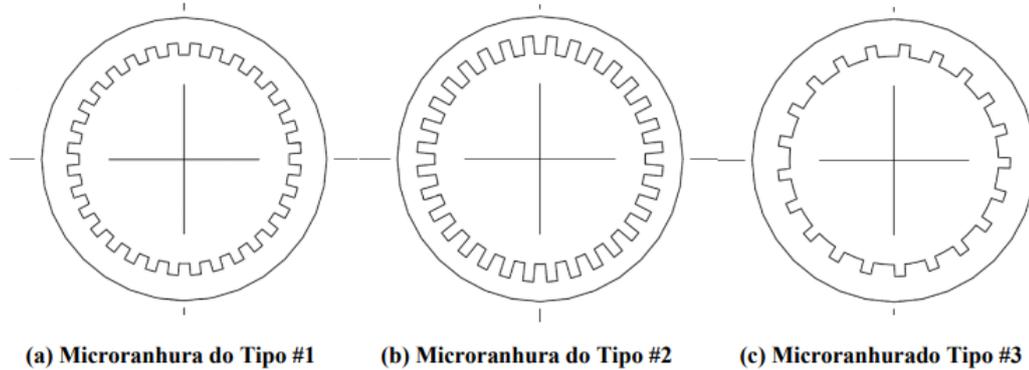
## 5.2 Tubos de calor

Nesta seção são apresentadas as informações sobre os trabalhos cujos resultados experimentais foram utilizados para a formação do banco de dados de tubos de calor. Uma tabela contendo todos os dados utilizados no treinamento das RNA pode ser visualizada no Anexo B.

### 5.2.1 Ranhuras axiais

Foram selecionados do trabalho de Nishida (2016) e Nishida *et al.* (2020) dados referentes a tubos de calor com microranhuras axiais. Os tubos de calor utilizados foram usinados utilizando o processo de eletroerosão a fio nos tubos de cobre. Com isso foram fabricados três diferentes modelos de microranhuras axiais que podem ser vistas na Figura 16.

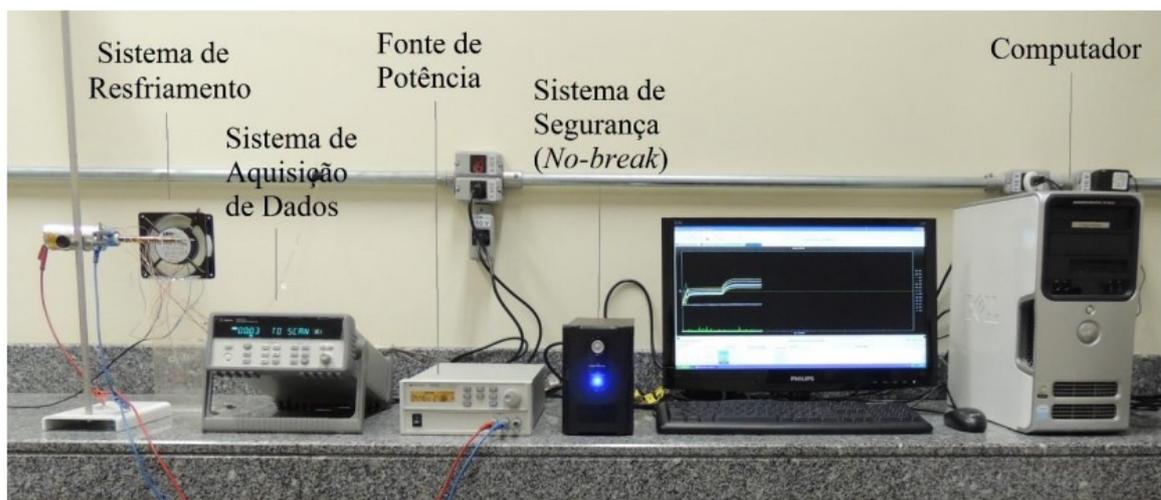
**Figura 16 - Tipos de microranhuradas axiais utilizadas**



**Fonte: Nishida (2016)**

A Fotografia 2 mostra o aparato experimental utilizado que inclui uma fonte de potência *Agilent™* U8002A, um sistema de aquisição de dados *Agilent™* 34970A com multiplexador de 20 canais, um microcomputador *Dell™*, um ventilador *Ultrar™*, um suporte universal e um *nobreak* *NHS™*. A avaliação do comportamento térmico dos tubos de calor foi avaliada utilizando termopares *Omega Engineering™* do tipo K, fixados na superfície externa dos tubos de calor utilizando uma fita adesiva termossensível.

**Fotografia 2 - Aparato experimental - Nishida (2016)**



**Fonte: Nishida (2016)**

A potência utilizada foi inicialmente de 5W. Após atingida a condição de regime quase estacionário a temperatura foi aumentada em 5W. O processo foi repetido até que a temperatura limite de 150°C fosse atingida. O fluido de trabalho utilizado foi a água destilada, com razão de preenchimento igual a 60% do evaporador. Foram realizados testes em seis diferentes inclinações.

### 5.2.1.1 Dados utilizados

Para a utilização nesse trabalho foram selecionados tubos de calor com micro ranhuras do Tipo #1, pois essas tiveram os melhores resultados dentre aquelas experimentados. Também foram selecionados apenas as configurações com inclinações positivas por essas terem um comportamento térmico diferente das inclinações negativas (ou maiores que 90°) e se mostrarem mais eficientes. A Tabela 2 mostra as informações sobre os dados selecionados. Um total de 27 dados experimentais foram selecionados.

**Tabela 2 - Informações sobre os parâmetros utilizados nos testes selecionados - NISHIDA (2016)**

<b>Inclinação de Trabalho [°]</b>	0, 45 e 90
<b>Razão de Preenchimento [%]</b>	60
<b>Potência Dissipada [W]</b>	5, 10, 15, 20, 25, 30, 35, 40, 45 e 50
<b>Ranhura Axial</b>	Tipo #1

**Fonte: Autoria Própria (2023)**

### 5.2.2 Pó Metálico Sinterizado

Os dados adquiridos por Krambeck (2018) foram utilizados para a formação do banco de dados com os resultados de tubos de calor com estruturas capilares de pó de cobre sinterizado.

A estrutura capilar sinterizada utilizada no estudo foi fabricada a partir de pó de cobre XF obtido por meio de atomização a gás. O material foi então sinterizado a uma taxa de aquecimento de 20°C/min e mantido por 15 minutos a uma temperatura de 800°C e resfriado naturalmente até cerca de 450°C. Após isso o resfriamento aconteceu por meio de convecção forçada até temperatura ambiente.

O processo de sinterização apresenta diversos parâmetros que influenciam nas características da estrutura porosa dos tubos de calor. Assim, para uma correta avaliação foi necessária a determinação de propriedades importantes sobre a estrutura capilar fabricada. Para a determinação da porosidade foi utilizada a técnica de imersão em água destilada, uma adaptação da Norma MPFI *Standard* 42 (METAL POWDER INDUSTRIES FEDERATION, 1997). Técnica que é baseada no Princípio de Arquimedes. A permeabilidade foi determinada com a realização de um ensaio de extrusão capilar baseado na Norma MPFI *Standard* 39 (METAL POWDER

INDUSTRIES FEDERATION, 1997), mesma norma utilizada para a medição do raio crítico da estrutura capilar utilizada. Enquanto a condutividade térmica efetiva da estrutura capilar de pó de cobre sinterizada foi determinada por meio de uma bancada experimental desenvolvida baseada no princípio da placa quente protegida, uma adaptação da NBR 15220 - Parte 04 (ABNT, 2003).

Os tubos de calor foram construídos utilizando a metodologia descrita em Antonini Alves, Krambeck e Santos (2018). As dimensões dos termossifões fabricados são mostradas no Quadro 1. Três diferentes espessuras de estrutura porosa foram utilizadas 2,125mm (Tipo #1), 1,500mm (Tipo #2) e 0,875mm (Tipo #3). A Fotografia 3 apresenta amostras de cada tipo de tubo de calor construído.

**Fotografia 3 - Amostra das diferentes configurações de estruturas capilares de pó de cobre sinterizadas**



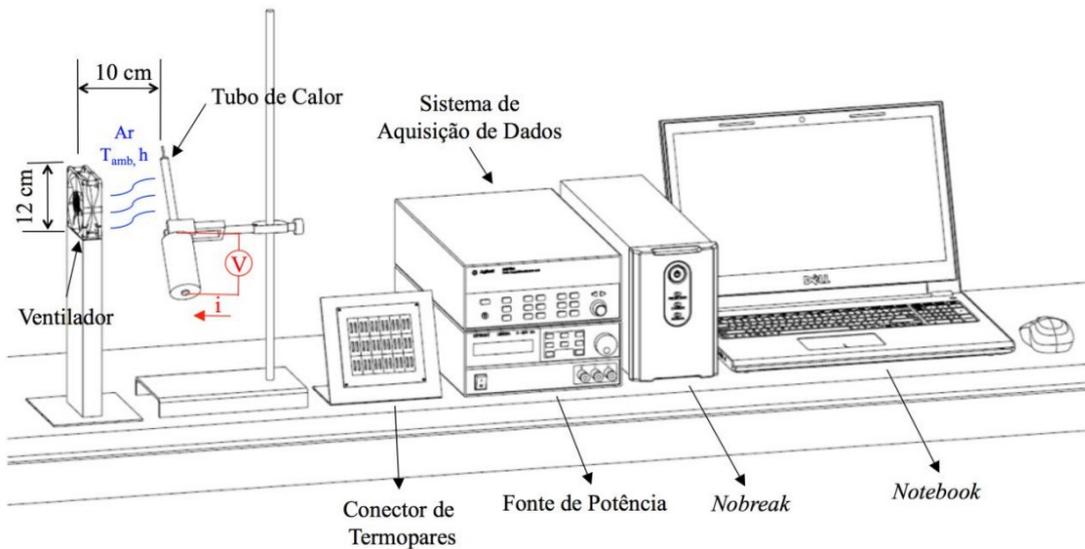
Fonte: Krambeck (2018)

O aparato experimental utilizado é mostrado esquematicamente na Figura 17. Para a realização do experimento foi necessário: uma de fonte de alimentação *Agilent*<sup>TM</sup> U8002A, um sistema de aquisição de dados *Agilent*<sup>TM</sup> 34970A com um multiplexador *Agilent*<sup>TM</sup> 34901A, um *notebook Dell*<sup>TM</sup> e um ventilador *Ultrar*<sup>TM</sup>, um suporte universal com garra e um nobreak *NHS*<sup>TM</sup>.

Para avaliação do comportamento térmico dos tubos de calor, foram utilizados termopares *Omega Engineering*<sup>TM</sup> do Tipo K fixados na superfície externa ao longo do comprimento dos tubos de calor, sendo três termopares fixados no evaporador, um termopar na seção adiabática e quatro no condensador.

Os testes foram realizados com potências dissipadas de 5W a 45W com passos de 5W, evitando a temperatura crítica de 150°C. Foram utilizadas também quatro diferentes razões de preenchimento e seis diferentes inclinações de trabalho. Um total de 360 diferentes configurações foram testadas.

**Figura 17 - Desenho esquemático do aparato experimental - Krambeck (2018)**



**Fonte: Krambeck (2018)**

### 5.2.2.1 Dados utilizados

Para esse trabalho foram selecionados apenas os dados dos tubos de calor com espessura de 0,875 mm (Tipo #3) que apresentaram os melhores resultados nos testes executados, e apenas as inclinações de trabalho positivas, que em geral apresentam resultados com maiores viabilidades de aplicação. Assim um total de 102 dados de diferentes configurações foram utilizadas para o treinamento das RNA. A Tabela 3 mostra um compilado dos parâmetros utilizados.

**Tabela 3 - Parâmetros utilizados nos testes dos dados selecionados - Krambeck (2018)**

<b>Inclinação de Trabalho [°]</b>	0, 45 e 90
<b>Razão de Preenchimento [%]</b>	60, 80, 100 e 120
<b>Potência Dissipada [W]</b>	5, 10, 15, 20, 25, 30, 35, 40 e 45
<b>Espessura da Estrutura Capilar [mm]</b>	0,875 (Tipo #3)

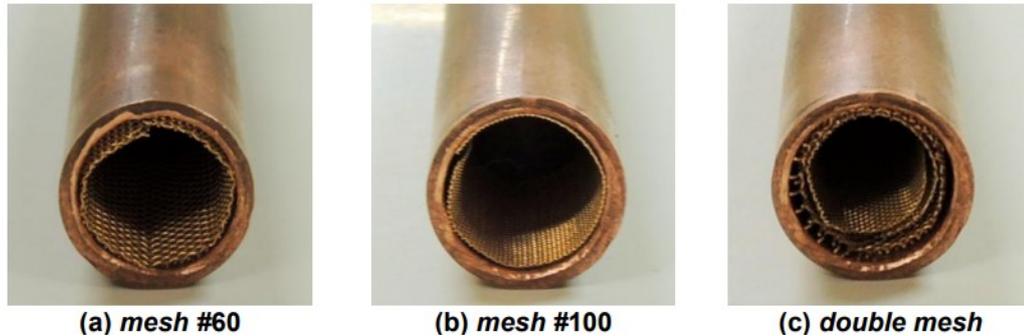
**Fonte: Autoria Própria (2023)**

### 5.2.3 Tela metálica

Os dados sobre o comportamento experimental de tubos de calor utilizando telas metálicas como estrutura capilar foram retirados dos resultados obtidos por Krambeck (2016). Foram avaliados experimentalmente a utilização de três diferentes tipos de telas metálicas, todas compostas por bronze fosforoso, que podem ser vistas na Fotografia 4. Essas diferentes configurações são: tubos de calor com uma única

camada de tela metálica de *mesh* #60 (Fotografia 4(a)), com uma única camada de *mesh* #100 (Fotografia 4(b)), e uma superposição de duas camadas de malha, uma de *mesh* #60 e outra de *mesh* #100 (Fotografia 4(c)) – *double mesh*.

**Fotografia 4 - Configurações de malhas**



Fonte: Krambeck (2016)

A bancada de testes utilizada nesse estudo é a mesma utilizada no trabalho de Nishida (2016) e mostrada na Fotografia 2. Os testes experimentais foram realizados com temperatura ambiente controlada em  $20,0^{\circ}\text{C} \pm 0,5^{\circ}\text{C}$ . O ventilador utilizado para gerar convecção forçada foi mantido a velocidade de 5m/s. Foram testadas cinco diferentes inclinações de trabalho, com potência dissipada variando entre 5W e 50W de 5W em 5W respeitando a temperatura máxima de  $150^{\circ}\text{C}$ . A razão de preenchimento em todos os testes foi de 60% do evaporador.

#### 5.2.3.1 Dados utilizados

Para esse trabalho foram selecionados os tubos de calor utilizando *mesh* #100 como estrutura capilar por apresentarem os melhores resultados dentre aqueles avaliados, foram também selecionadas apenas as inclinações de trabalho positivas por apresentarem resultados mais relevantes. A Tabela 4 apresenta um compilado dos dados selecionados do estudo de Krambeck (2016). Um total de 27 dados foram selecionados.

**Tabela 4 - Informações sobre os parâmetros utilizados nos testes selecionados - Krambeck (2016)**

<b>Inclinação de Trabalho [°]</b>	0, 45 e 90
<b>Razão de Preenchimento [%]</b>	60
<b>Potência Dissipada [W]</b>	5, 10, 15, 20, 25, 30, 35, 40, 45 e 50
<b>Malha da Tela Metálica</b>	<i>Mesh</i> #100

Fonte: Autoria Própria (2023)

## 6 METODOLOGIA

Nesta seção são apresentados os detalhes sobre a metodologia adotada no decorrer dessa Dissertação de Mestrado em Engenharia Mecânica. Nesta parte são apresentados os detalhes sobre as RNA utilizadas (ELM, RBF e MLP) e seus respectivos treinamentos para a obtenção dos resultados.

### 6.1 Treinamento das RNA

O parâmetro escolhido para avaliação do desempenho térmico dos termossifões é a resistência térmica que pode ser expressa por:

$$R_{th} = \frac{(T_{evap} - T_{cond})}{q_{in}}, \quad (47)$$

sendo que,  $T_{evap}$  e  $T_{cond}$  são as temperaturas médias do evaporador e condensador respectivamente,  $R_{th}$  é a resistência térmica e  $q_{in}$  é a potência dissipada. Assim foi possível determinar a resistência térmica para cada configuração testada. A compilação do resultado completo pode ser visualizada no Apêndice A.

Cada RNA foi treinada avaliando diferentes números de neurônios em sua camada oculta, de modo a obter o menor Erro Quadrático Médio (MSE – do inglês, *Mean Squared Error*) em relação aos dados de teste. Para cada uma das redes utilizadas, foram variados alguns aspectos, a depender das características de cada uma. Um resumo do treinamento pode ser visto no Quadro 3.

**Quadro 3 - Valores utilizados no Treinamento**

Modelo	Nº de neurônios	Passo	Nº de camadas ocultas	Função de ativação	
				Oculto	Saída
MLP	3 - 200	0,004	1	Logística	Linear
RBF	3 - 200	0,004	1	<i>Gaussiana</i>	Linear
ELM	3 - 200	N/A	1	Logística	Linear

Fonte: Autoria Própria (2023)

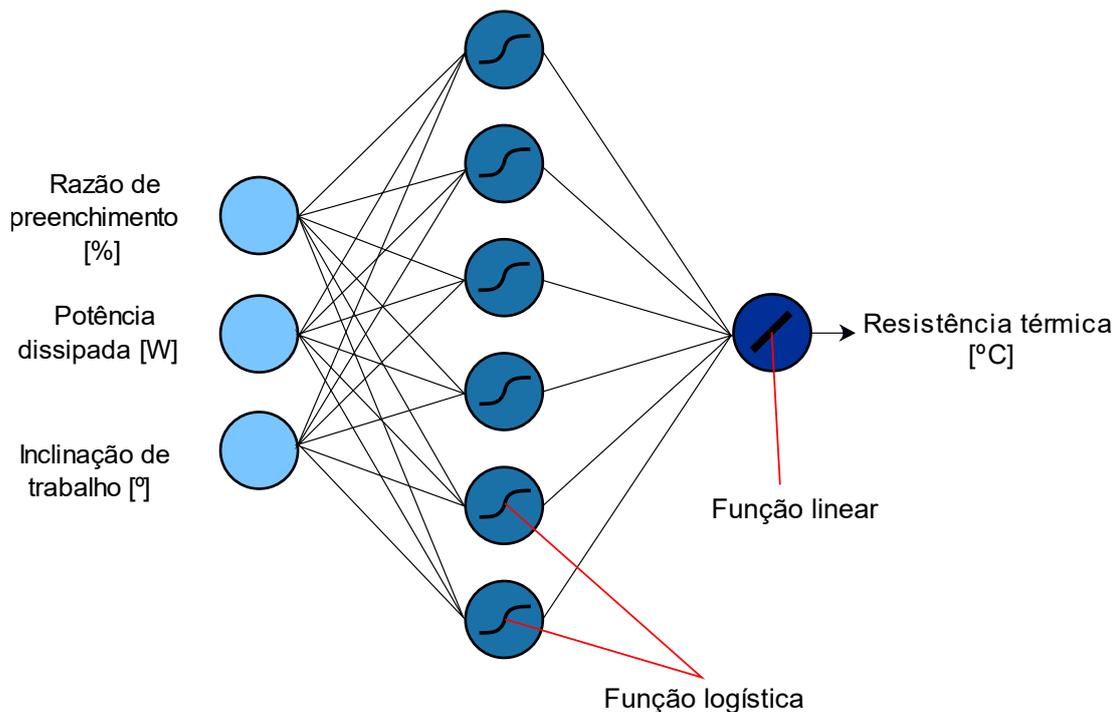
O valor proposto para o passo de aprendizado para as Redes MLP e RBF poderia ser modificado caso necessário para interferir no tempo de treinamento. Ele pode ser diminuído caso a convergência se mostre rápida o suficiente ou aumentado caso os tempos de processamento se tornem impeditivos. Porém, como não houve limitação em relação ao tempo de treinamento, o valor foi mantido constante.

Como entradas para as RNA para os termossifões foram utilizados: a razão de preenchimento, potência dissipada e inclinação de trabalho. Enquanto para os tubos de calor também são incluídos a condutividade efetiva calculada pelas Equações (15), (18) e (19) e o tipo do tubo de calor representado por um valor numérico arbitrário entre 1 e 3. Ambas as propriedades dependem da estrutura capilar utilizada. A saída é a resistência térmica em regime permanente para ambos os casos.

### 6.1.1 MLP

A Figura 18 mostra a configuração de uma Rede Neural Artificial MLP com as entradas utilizadas para os dados de termossifões. Esse exemplo contém 6 neurônios na sua única camada oculta utilizando a função de logística nessa camada e uma função linear na camada de saída.

**Figura 18 - Configuração da Rede MLP utilizada**



**Fonte: Autoria Própria (2023)**

Para o treinamento da Rede Neural *Perceptron* de Múltiplas Camadas o conjunto de dados foi separado em três:

- Grupo de *Treinamento*: com cerca de 70% dos dados que são os quais são efetivamente utilizados nos ciclos de treinamento da rede;
- Grupo de *Validação*: contendo 15% dos dados os quais são utilizados como critério de parada para evitar o sobre-treinamento;
- Grupo de *Testes*: contendo 15% dos dados onde a rede neural treinada é avaliada quanto a dados desconhecidos.

Os pesos iniciais foram obtidos aleatoriamente e não foi utilizado termo de momento. Duas etapas foram utilizadas para o treinamento dessa rede:

### **Etapa 1**

O treinamento foi realizado variando os parâmetros escolhidos, de modo a selecionar as combinações que minimizam o *MSE* entre a saída da rede e o resultado esperado. O passo utilizado foi de 0,004 (pode ser variado em caso de necessidade).

Inicialmente a RNA foi treinada apenas com os dados de treinamento e um número constante e reduzido de 10.000 ciclos de modo a avaliar o funcionamento correto e a convergência. Observados resultados positivos foi iniciado o processo de varredura em busca das combinações com menores erros possíveis.

As variações foram:

- a) número de neurônios na camada oculta: entre 3 e 200 aumentando o número de 3 em 3;
- b) número de camadas ocultas entre 1 e 2;
- c) as funções de ativação na camada oculta.

Feito isso, o processo de treinamento foi realizado novamente, agora, com um número máximo de 50.000 ciclos. A cada iteração foi testado um critério de parada que ocorreu pela comparação do erro quadrático obtido ao aplicar os valores dos dados de validação, a rede neural no estado atual e compará-los com os resultados esperados. Caso o critério de parada não seja alcançado no ciclo atual os valores dos pesos da rede são atualizados utilizando o Algoritmo *Backpropagation* usando resultados obtidos com os dados de treinamento. A cada iteração também foi avaliado se o Erro Quadrático Médio de validação atual foi o menor, caso seja, esse grupo de

pesos foi salvo e só seria substituído caso um erro ainda menor fosse encontrado, garantindo que melhor grupo de pesos fosse guardado mesmo que as iterações continuassem. Ao final do processo de varredura esses pesos salvos foram utilizados para a etapa de teste que consiste da aplicação dos dados de teste, que ainda não são *conhecidos* pela rede, na RNA com os pesos encontrados e avaliação do *MSE* resultante. Para cada combinação de parâmetros foram realizados dez testes e o valor médio entre eles foi avaliado.

### **Etapa 2**

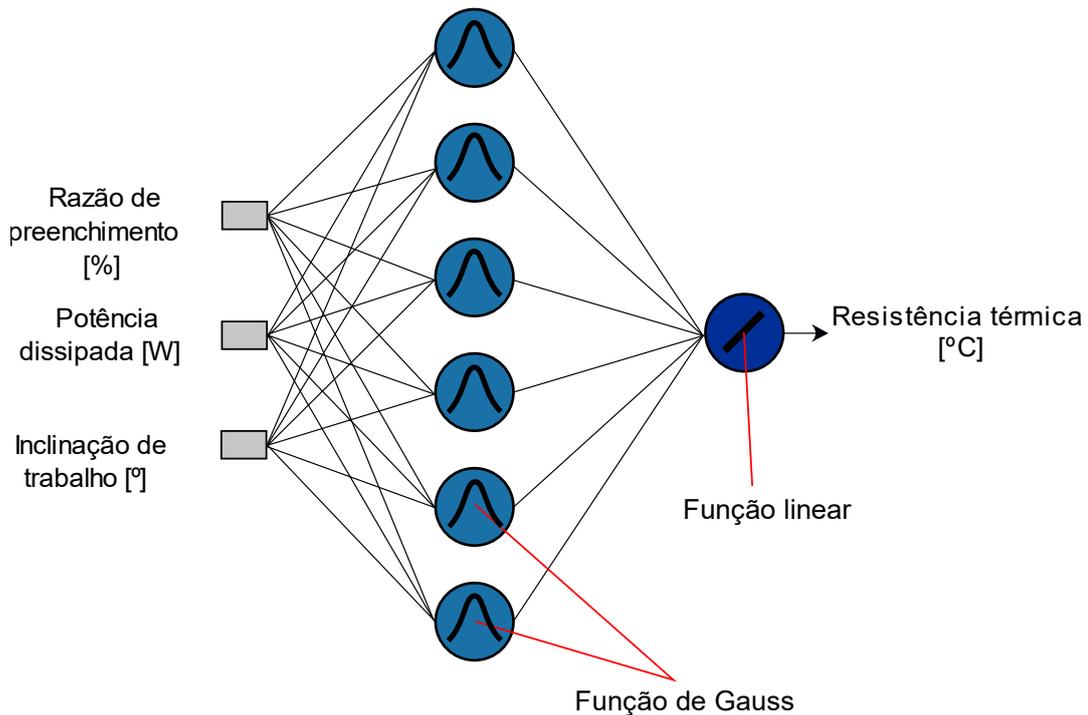
As combinações com os menores erros de teste foram selecionadas e então, testadas em uma nova varredura mais profunda, com um aumento do número de repetições dos testes de 10 para 30. Aqui, novamente, foram utilizados como critério de parada os dados de validação, porém o erro aceitável pelo critério de parada foi reduzido de modo treinar a rede neural por mais ciclos e ter resultados finais com erro reduzido. Assim como na etapa anterior o resultado final de cada treinamento consiste da avaliação do comportamento da rede utilizando os dados de teste.

As etapas 1 e 2 foram repetidas para cada combinação de funções de ativação possíveis para a rede neural. O resultado vem da comparação dos melhores resultados obtidos em cada caso

#### 6.1.2 RBF

A configuração de uma Rede Neural Artificial RBF com 6 neurônios na camada oculta utilizando a função de *Gauss* na camada oculta e uma função linear na camada de saída é mostrada na Figura 19. Esse exemplo apresenta as três entradas utilizada pelos dados de termossifões: razão de preenchimento, potência dissipada e inclinação de trabalho, que foram inseridas diretamente na camada escondida. A saída é a resistência térmica em regime permanente.

Figura 19 - Rede RBF



Fonte: Autoria Própria (2023)

A Rede RBF tem uma grande relação entre o número de neurônios da camada oculta e a qualidade dos resultados. Em alguns casos, o valor ótimo de neurônios pode ser tão alto quanto a quantidade de dados de entrada disponíveis. Por esse motivo, foi utilizado um valor maior de número de neurônio a serem testados, se comparado à MLP. O conjunto de dados é dividido como no caso da MLP, entre treinamento, validação e teste. A função de ativação foi a Função de *Gauss*, que não foi modificada durante a avaliação.

### Etapa 1

Inicialmente, para cada treinamento da rede neural devem ser encontrados os centros das funções *Gaussianas* utilizando de uma combinação dos algoritmos *k-means* e PSO. O único parâmetro a ser variado para a Rede RBF foi o número de neurônios, entre 3 e 200, com o número de camadas ocultas e as funções de ativação mantidas constantes. O passo de aprendizagem utilizada foi de 0,004 assim como no caso da Rede MLP. Os números de neurônios que apresentaram menores energias de erro foram selecionadas para a Etapa 2.

Foi também avaliado o tempo gasto para finalizar o treinamento, uma vez que o aumento no número de neurônios implica em maior número de cálculos e conseqüentemente maior tempo de processamento, o maior número de neurônios na

camada oculta da Rede RBF em comparação com a Rede MLP pode impactar no tempo de treinamento da rede neural.

## **Etapa 2**

A segunda etapa do treinamento da Rede RBF segue os mesmos parâmetros vistos na Etapa 2 do treinamento da Rede MLP, mostrada na Seção 6.1.1.

Com os resultados, o tempo de treinamento deve ser novamente avaliado com as configurações selecionadas. Caso o tempo seja impeditivo, uma nova avaliação deve ser realizada, reduzindo os números máximos de neurônios na camada oculta a serem avaliados.

### 6.1.3 ELM

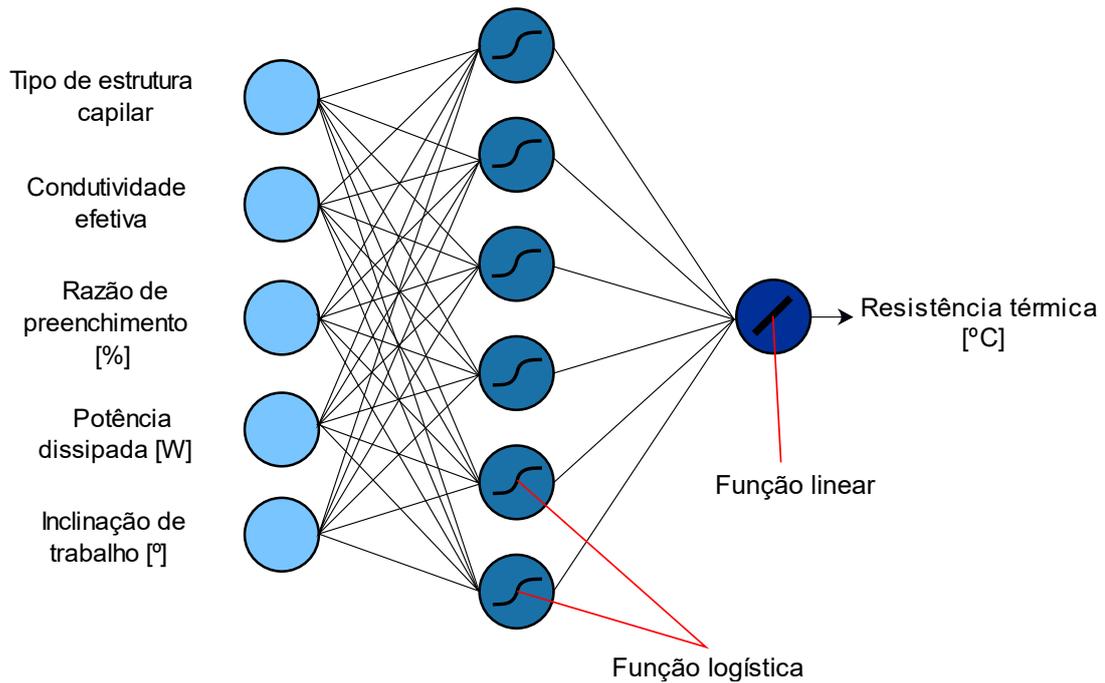
A configuração de uma Rede ELM com 6 neurônios na camada oculta utilizando a função logística na camada oculta é mostrada na Figura 20. As entradas desse exemplo representam as utilizadas com tubos de calor, contendo o tipo de estrutura capilar, a condutividade efetiva, razão de preenchimento, potência dissipada e inclinação de trabalho do termossifão. A saída é a resistência térmica em regime permanente.

A Máquina de Aprendizado Extremo trabalha sem iterações, uma vez que a camada intermediária não é ajustada e sua camada de saída é treinada analiticamente, o que reduz o tempo de treinamento nesse caso.

A Rede ELM foi treinada variando os parâmetros de modo a selecionar as combinações que minimizam o *MSE* entre a saída da rede neural e o resultado esperado. Ao contrário da Rede MLP e da Rede RBF, para a Rede ELM não é utilizada validação e por isso os dados foram divididos em dois grupos:

- Grupo de *Treinamento*: com cerca de 85% dos dados, os quais são efetivamente utilizados no treinamento da rede;
- Grupo de *Teste*: com 15% dos dados utilizado para avaliar o erro da rede no final do treinamento.

Figura 20 - Rede ELM



Fonte: Autoria Própria (2023)

As variações foram:

- a) número de neurônios na camada oculta, variados entre 3 e 200;
- b) número de camadas ocultas entre 1 e 2;
- c) função de ativação da camada oculta.

Ao final dos cálculos foram selecionadas as melhores combinações da rede neural, ou seja, os valores que minimizaram o *MSE*. Para diminuir a influência da condição inicial nos resultados foram realizados, para cada combinação, dez testes e o valor médio entre eles foi avaliado.

As combinações com os menores erros foram então avaliadas com um aumento no número de repetições dos testes de 10 para 30. Assim como nas Redes MLP e RBF, o resultado de cada treinamento foi avaliado em um grupo de teste com dados desconhecidos à rede neural.

## 7 RESULTADOS

Neste capítulo, são apresentados os resultados obtidos durante esse estudo, bem como as métricas de avaliação utilizadas e o significado dos resultados obtidos. São também apresentadas algumas hipóteses sobre os valores alcançados.

A comparação entre os valores encontrados por equações teóricas e valores experimentais para dispositivos como tubos de calor e termossifões não é abordada com frequência na literatura. Assim, como base de avaliação para os resultados obtidos é utilizado um valor adquirido com base em experimentos. O valor utilizado para definir um resultado dentro do aceitável é de 30% de Erro Percentual Absoluto Médio (*MAPE*, do inglês *Mean Absolute Percentual Error*) (Equação (48)). Valores maiores representam uma variação na resistência térmica esperada que gera perdas significativas do ponto de vista experimental.

Além do *MAPE*, também foram utilizados para a avaliação dos resultados o Erro Absoluto Médio (*MAE*, do inglês *Mean Absolute Error*) que representa a média do valor absoluto dos erros encontrados (Equação (49)) e a Raiz Quadrada do Erro Quadrático Médio (*RMSE*, do inglês *Root Mean-Square Error*) que é semelhante ao *MAE*, mas é mais punitiva para valores maiores de erro absoluto (Equação (50)).

Diferentes métodos de avaliação dos erros são importantes, uma vez que, em muitos casos, apenas uma métrica não é capaz de expressar com clareza os resultados. Nesses casos, pode ser importante se utilizar de diferentes métodos para se entender com confiança os valores obtidos.

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{d_t - y_t}{d_t} \right| 100, \quad (48)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |d_t - y_t|, \quad (49)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (d_t - y_t)^2}, \quad (50)$$

sendo que,  $d_t$  representa a saída experimental do banco de dados,  $y_t$  é a saída das redes neurais e  $N$  representa o número de dados utilizado.

## 7.1 Termossifões

Para cada modelo de RNA utilizado foi selecionado o número de neurônio que mostrou os melhores resultados. No Quadro 4 são apresentados os erros alcançados por cada rede neural. O valor *NN* representa o número de neurônios na camada oculta. Os valores foram obtidos a partir da média dos erros entre 30 testes independentes.

**Quadro 4 - Erros encontrados para a melhor configuração de cada rede - termossifões**

Modelo	<i>NN</i>	Função na camada oculta	Nº de camadas ocultas	<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i> [%]
MLP	9	Logística	1	0,214	0,258	8,24
RBF	90	<i>Gaussiana</i>	1	0,180	0,216	5,85
ELM	25	Logística	1	0,205	0,248	6,71

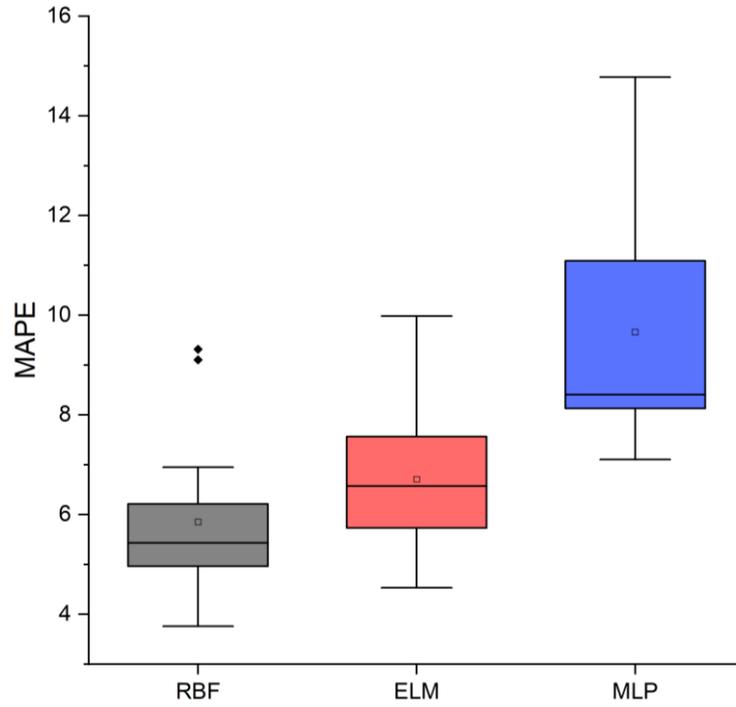
Fonte: Autoria Própria (2023).

Os resultados mostraram que todas as redes neurais testadas tiveram sucesso em generalizar o banco de dados de termossifões, uma vez que todas apresentaram erros abaixo do esperado para esse tipo de problema.

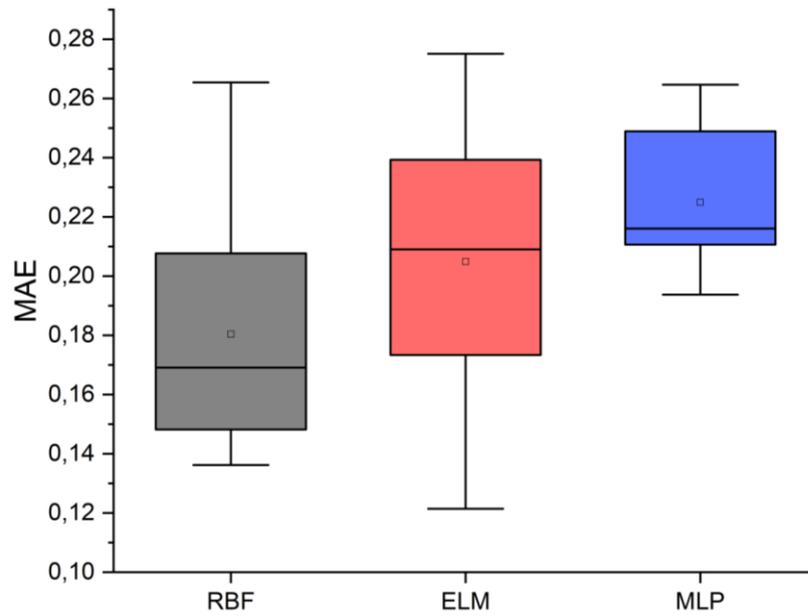
Os Gráficos 3, 4 e 5 mostram as representações em diagramas de caixa (*boxplot*) para os Erros *MAPE*, *MAE* e *RMSE*, calculados para as 30 simulações realizadas para cada uma das redes neurais utilizadas.

Como pode ser observado, a Rede RBF apresenta resultado ligeiramente melhor que a rede ELM que, por sua vez, apresenta um resultado um pouco melhor que a Rede MLP. Mesmo assim, os resultados mostrados por todas as RNA podem ser considerados bons, uma vez que estão bem abaixo do valor de 30% esperado e visto que a média e a dispersão são baixas em todos os casos.

O Gráfico 6 mostra a comparação entre as resistências térmicas dos termossifões obtidas experimentalmente do banco de dados para teste e os valores calculados em uma simulação utilizando cada uma das redes neurais avaliadas. É possível perceber que não só os valores médios de erro, mostrados nos diagramas de caixa (Gráficos 3, 4 e 5), apresentam resultados consistentes, como também os valores individuais obtidos pela simulação demonstram proximidade com o valor experimental utilizado, tendo 100% do grupo de teste dentro da área que representa erro menor que 30%.

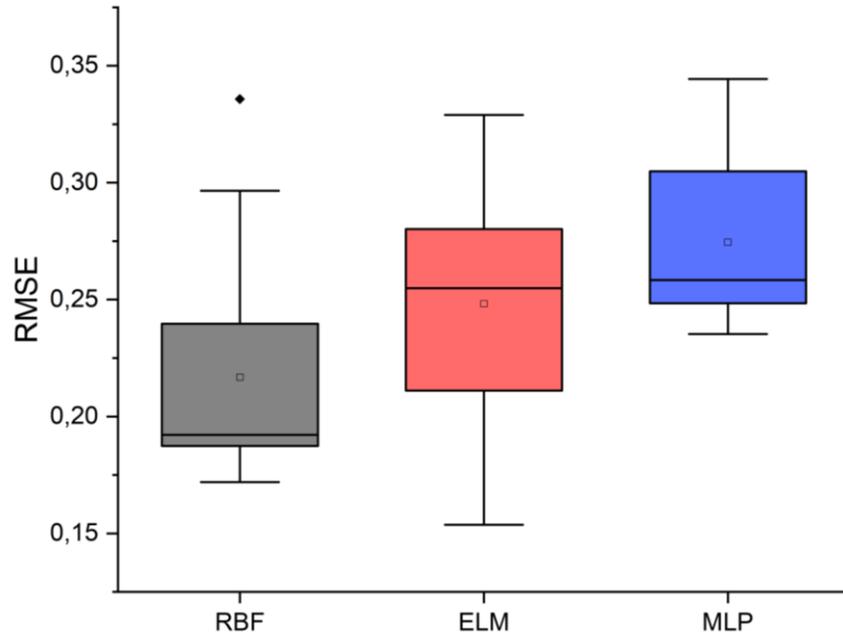
**Gráfico 3 - Diagrama de caixa para o MAPE das 30 simulações - termossifões**

Fonte: Autoria Própria (2023)

**Gráfico 4 - Diagrama de caixa para o MAE das 30 simulações - termossifões**

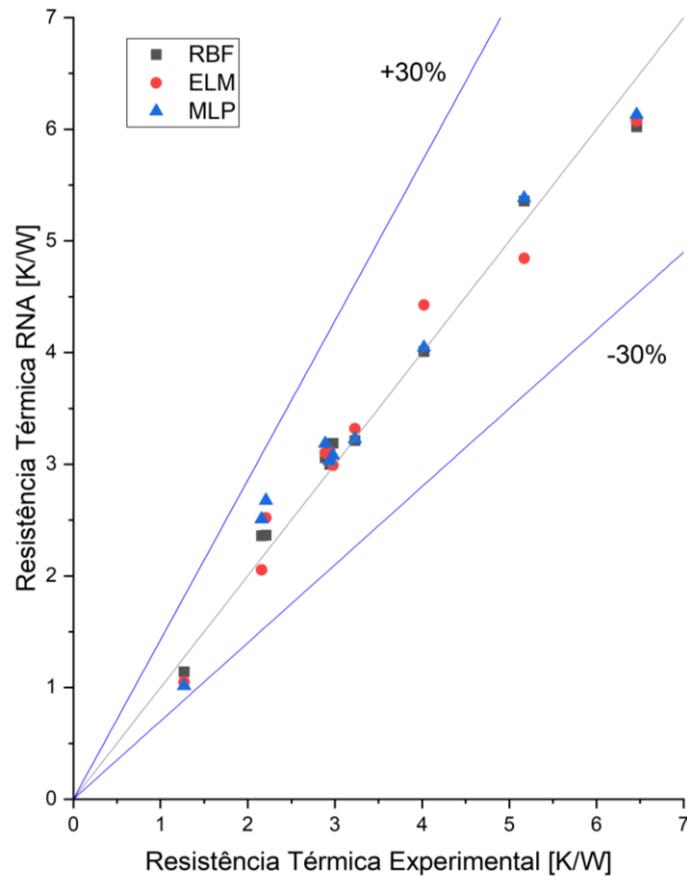
Fonte: Autoria Própria (2023)

Gráfico 5 - Diagrama de caixa para o *RMSE* das 30 simulações - termossifões



Fonte: Autoria Própria (2023)

Gráfico 6 - Comparação entre os valores experimentais e calculados para cada RNA com o valor experimental para os dados de termossifões



Fonte: Autoria Própria (2023).

Os resultados apresentados demonstram que a utilização das RNA é viável, e também uma excelente opção para a avaliação de termossifões. Esses resultados são válidos, dado o caráter de estudo inicial dessa Dissertação de Mestrado. É possível ressaltar que, o baixo número de variáveis nesse caso, em que as dimensões do termossifão, tipo de fluido de trabalho e materiais do invólucro não foram modificados, é provavelmente a causa da semelhança com que todas as RNA se adaptaram ao problema e geraram resultados próximos. Em um novo estudo mais complexo, pode-se esperar uma maior diferença entre os resultados exibidos por cada rede neural. Mesmo assim, os resultados são extremamente importantes, ainda mais se considerado que os erros encontrados estão bem abaixo do erro aceitável de 30%.

## 7.2 Tubos de calor

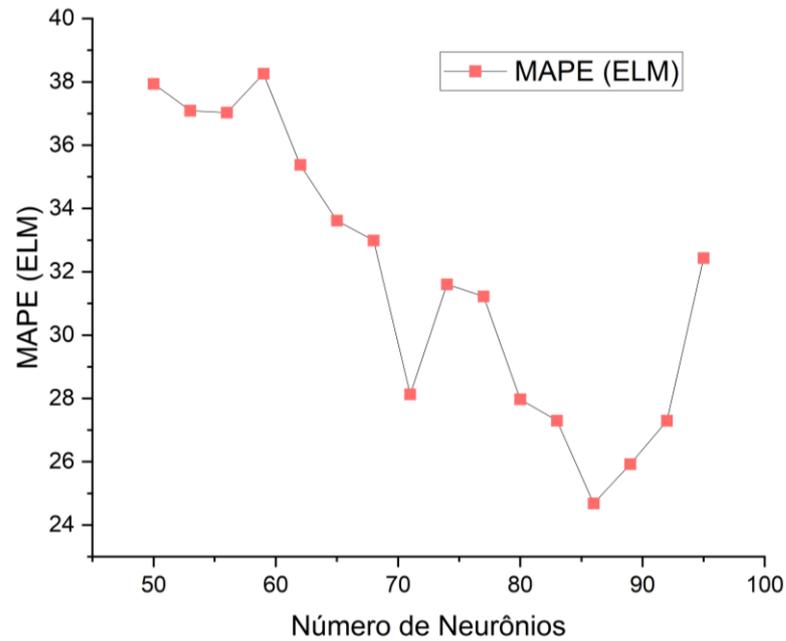
No Quadro 5 são apresentados os resultados obtidos para cada modelo de RNA utilizado para o banco de dados de tubos de calor. O valor *NN* representa o número de neurônios na camada oculta. Os valores foram obtidos a partir da média dos erros entre 30 testes independentes.

**Quadro 5 - Erros encontrados para a melhor configuração de cada rede – tubos de calor**

Modelo	<i>NN</i>	Função na camada oculta	Nº de camadas ocultas	<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i> [%]
ELM	84	Logística	1	0,285	0,384	25,74
MLP	15	Logística	1	0,241	0,409	13,96
RBF	102	<i>Gaussiana</i>	1	0,669	0,882	67,03

Fonte: Autoria própria (2023).

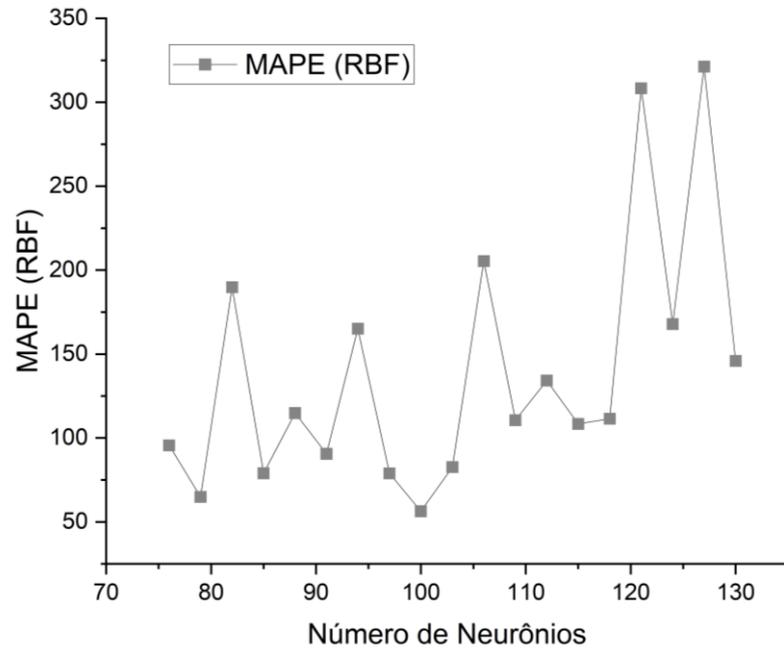
No Gráfico 7, pode ser observada a relação entre o *MAPE* e o número de neurônios na camada oculta para a Rede ELM. Observando os valores mostrados, pode ser notada uma tendência clara de diminuição do erro, que se inicia na região de 50 neurônios e continua até a região entre 80 e 90 neurônios, quando se inicia uma tendência de crescimento de erro. Esse gráfico mostra que esses valores, entre 80 e 90 neurônios, representam uma região de mínimo e que o número utilizado deve estar nessa região, o que concorda com a informação do Quadro 5 (84 neurônios).

**Gráfico 7 - Relação entre erro (*MAPE*) e número de neurônios para a Rede ELM**

Fonte: Autoria Própria (2023)

O Gráfico 8 mostra a variação do *MAPE* em relação ao número de neurônios para a Rede RBF na região do menor erro encontrado. Os resultados mostram que ao contrário das outras RNA testadas, não existe uma clara tendência para uma região de menor erro. Também é possível perceber uma menor relação entre o erro mostrado por um valor de número de neurônio e o erro exibido pelos valores próximos, que pode ser um sintoma apresentado pela má adaptação da Rede RBF ao problema.

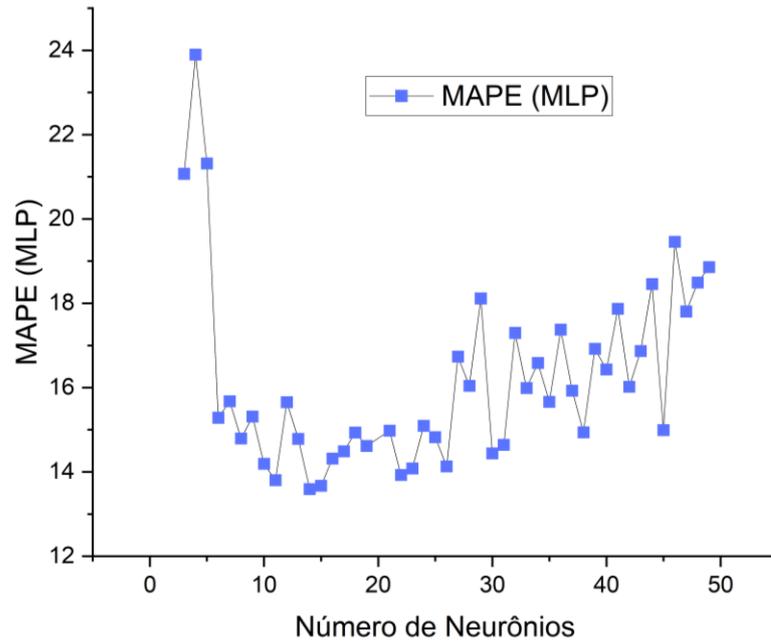
**Gráfico 8 - Relação entre erro (*MAPE*) e número de neurônios para a Rede RBF**



Fonte: Autoria Própria (2023)

O Gráfico 9 mostra a relação do *MAPE* com o número de neurônios na camada oculta para a Rede MLP na região próxima à do menor erro encontrado. É possível visualizar um rápido declínio no erro entre 3 e 10 neurônios, seguido por uma área de certa estabilidade. O erro cresce novamente e continuamente entre 20 e 50 neurônios. Embora menos claro que no caso da Rede ELM, ainda é possível visualizar a tendência do erro a diminuir conforme o valor se aproxima do número ótimo, mostrado no Quadro 5 (15 neurônios).

**Gráfico 9 - Relação entre erro (*MAPE*) e número de neurônios para a Rede MLP**



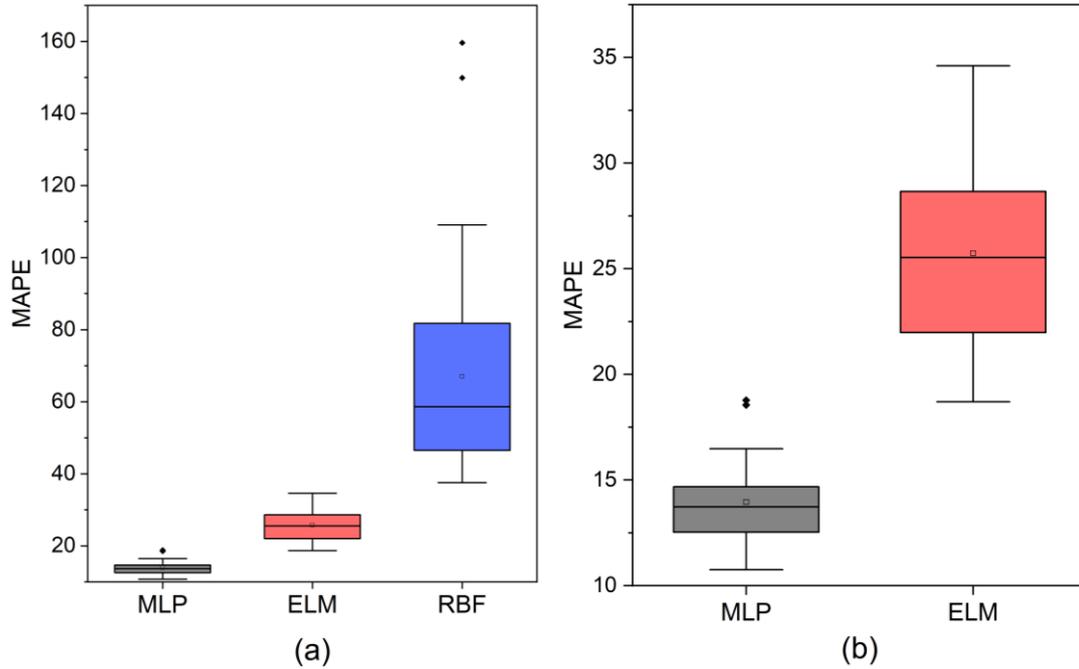
Fonte: Autoria Própria (2023)

Os resultados apresentados mostram que as Redes MLP e ELM são 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 apresenta melhores resultados em relação aos erros *MAPE* e *MAE* para esse problema. O *MAPE* encontrado para a Rede MLP é cerca de 45% menor que aquele apresentado pela Rede ELM. Enquanto que o *MAE*, é 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. Os Gráficos 10(a), 11(a) e 12(a) são os diagramas de caixa (*boxplot*) do *MAPE*, *RMSE* e *MAE*, respectivamente, calculados para as 30 simulações realizadas para cada rede neural utilizada. Os Gráficos 10(b), 11(b) e 12(b) apresentam os mesmos resultados, mas apenas para as Redes MLP e ELM.

Pode ser observado que a Rede ELM apresenta, se comparada a Rede MLP maior dispersão em relação ao *MAPE* (Gráfico 10). Os valores de *RMSE* encontrados para essas redes neurais foram bem próximos, tanto em média quanto dispersão (Gráfico 11), enquanto os valores encontrados para o *MAE* são ligeiramente melhores para a Rede ELM (Gráfico 12). Ambas as redes neurais apresentam resultado dentro do esperado e com valores aceitáveis para a avaliação de tubos de calor, que usualmente trabalham com grandes erros de projeto. A Rede RBF demonstra uma

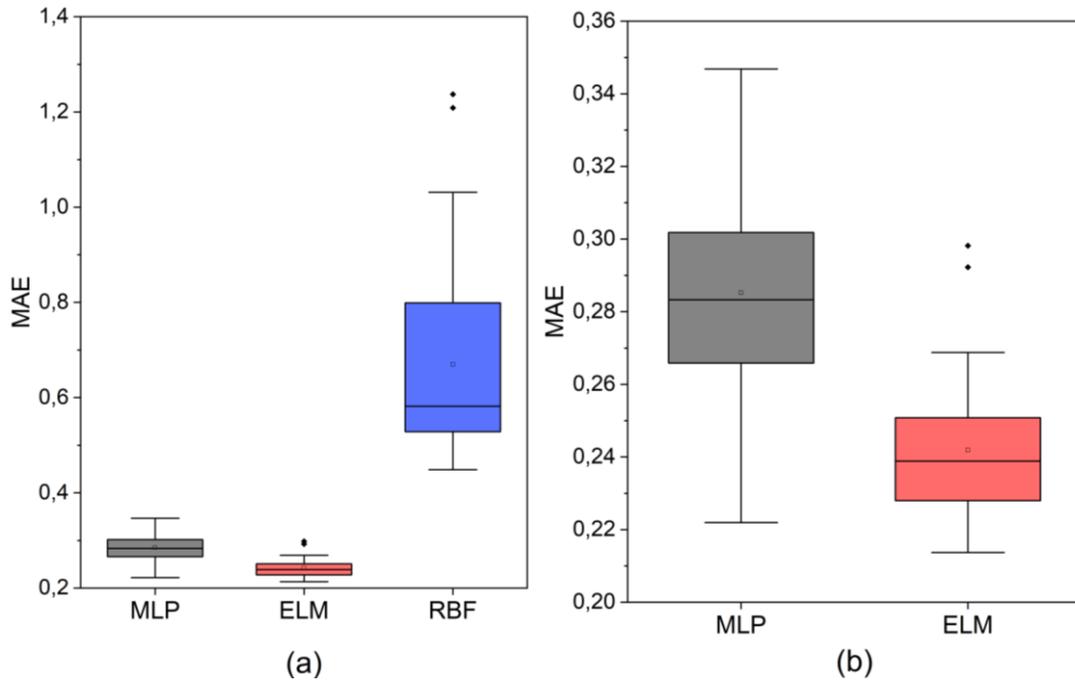
grande dispersão, já esperada, dado o maior erro médio mostrado, apontando que a RNA não foi capaz de mapear corretamente o problema.

**Gráfico 10 - Diagrama de caixa para o *MAPE* das 30 simulações para as redes neurais utilizadas (tubos de calor)**



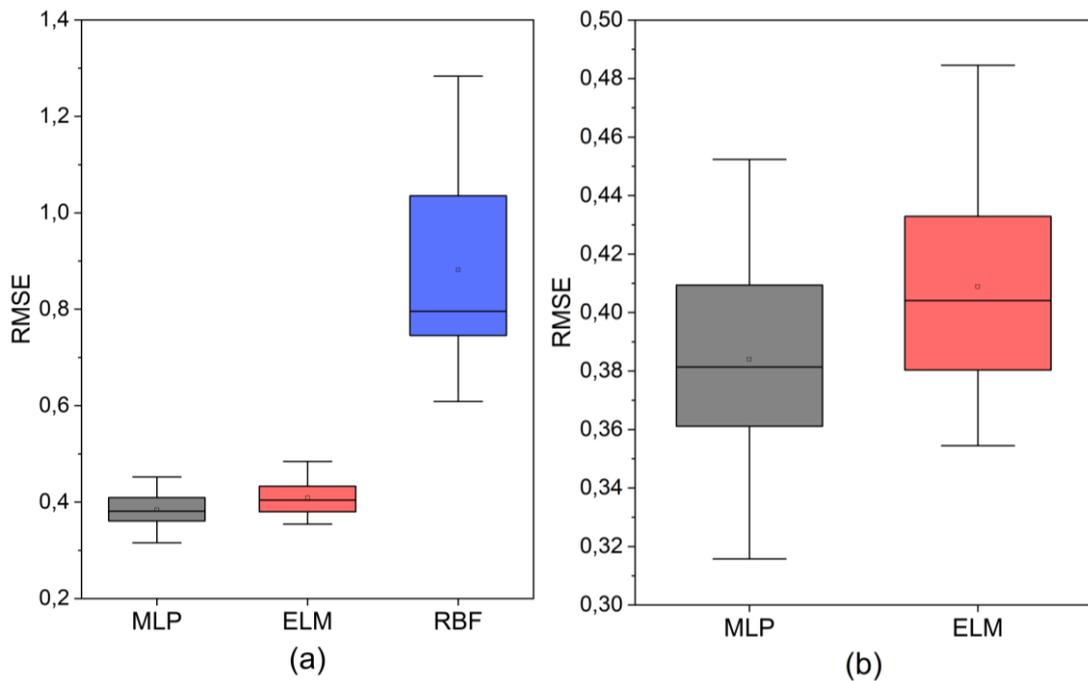
Fonte: Autoria Própria (2023)

**Gráfico 11 - Diagrama de caixa para o MAE das 30 simulações para as redes neurais utilizadas (tubos de calor)**



Fonte: Autoria Própria (2023)

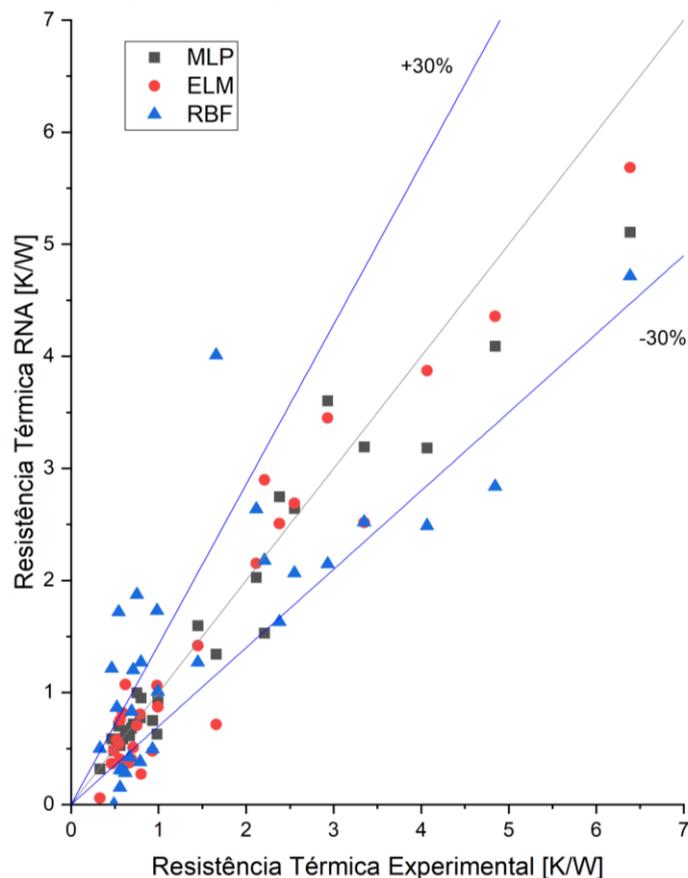
**Gráfico 12 - Diagrama de caixa para o RMSE das 30 simulações para as redes neurais utilizadas (tubos de calor)**



Fonte: Autoria Própria (2023)

O Gráfico 13 mostra a comparação entre as resistências térmicas dos tubos de calor obtidas experimentalmente e os valores obtidos utilizando as RNA. Em relação às Redes ELM e MLP, é possível visualizar que, além de gerarem bons valores médios de erro, mostrados nos diagramas de caixa, as redes neurais geram 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 têm comportamentos semelhantes nesse caso, apesar de a Rede ELM apresentar alguns pontos discrepantes (*outliers*). A Rede RBF, mais uma vez, apresenta resultados piores que as outras redes neurais com valores bem distantes dos valores ótimos.

**Gráfico 13 - Comparação entre os valores experimentais e calculados para cada RNA com o valor experimental para os dados de tubos de calor**

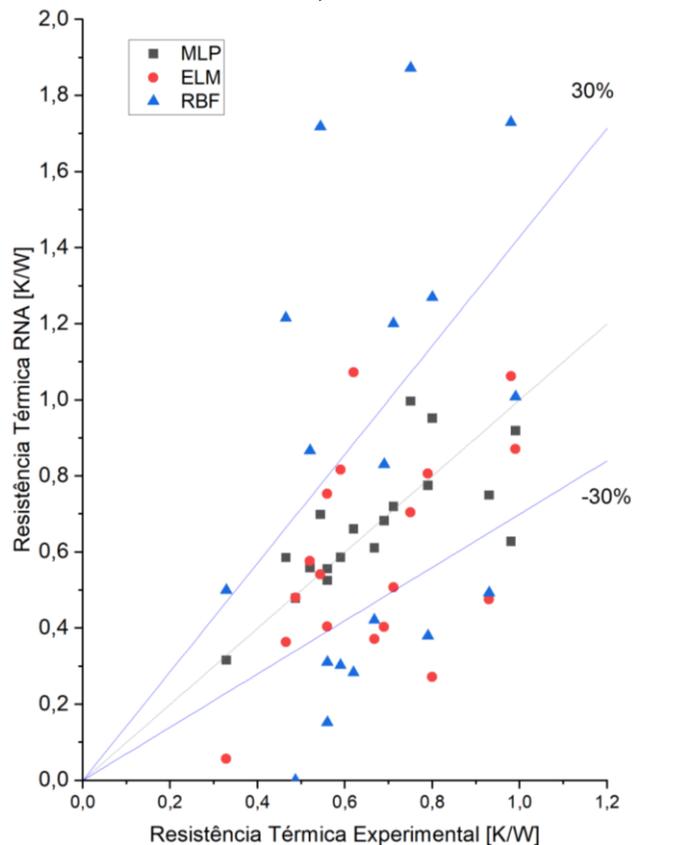


**Fonte: Autoria Própria (2023)**

O Gráfico 14 apresenta os mesmos resultados do Gráfico 13, 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 mostram as maiores divergências em porcentagem, com os experimentais. Os valores obtidos com a Rede ELM também apresentam muitos casos com erros maiores que 30% enquanto a Rede MLP é a única que apresenta resultados consistentemente dentro da faixa de erro esperada.

**Gráfico 14 - Comparação entre os valores experimentais e calculados para cada RNA com o valor experimental para os dados de tubos de calor para resistências térmicas menores que 1,2K/W**



**Fonte: Autoria Própria (2023)**

Os resultados apresentados pelas RNA nas simulações de tubos de calor se mostraram mais complexos do que aqueles apresentados pelos termossifões, gerando maiores tempos de simulação e maiores erros médios, além de comportamentos mais distintos entre as diferentes redes neurais, que pode significar uma maior dificuldade na adaptação ao problema. Essa maior dificuldade pode ser esperada, uma vez que tubos de calor têm maior complexidade de funcionamento e o banco de dados apresenta variação entre tipos de estrutura capilar, que tem grande influência no funcionamento do dispositivo passivo de transferência de calor.

Além disso, é clara a maior dificuldade da Rede RBF em se adaptar ao problema, o que se torna ainda mais aparente ao se considerar que a rede neural

obteve os melhores resultados para o caso de termossifões. Porém, algumas hipóteses podem ser feitas para explicar esse comportamento.

É necessário perceber que diferentes redes neurais, algumas vezes, têm diferentes comportamentos para os mesmos problemas, pelo fato de cada RNA ter um método próprio para alcançar o resultado, que pode muitas vezes causar divergências. Ainda assim, a diferença mais evidente da Rede RBF em relação às outras redes neurais são suficientes para se esperar a existência de outras causas, como a dependência da Rede RBF em relação à condição inicial, usualmente causada pelo algoritmo de treinamento não supervisionado responsável pela primeira parte do treinamento. Nesse trabalho, essa condição foi aliviada com a utilização do Algoritmo PSO em conjunto com o *k-means*, que se mostrou efetiva para o banco de dados de termossifões. Porém, esse método é limitado quando o número de neurônios aumenta muito, uma vez que o número de iterações e agentes do PSO devem aumentar simultaneamente, o que gera um aumento exponencial do tempo de processamento tornando-se um limitador da simulação. Assim, devido a esses problemas, os algoritmos utilizados se tornam menos eficientes com o aumento do número de neurônios, o que pode explicar parte dos resultados encontrados.

Dados os problemas da Rede RBF, a rede neural pode ser considerada não efetiva para esse problema, mas, visto que o objetivo nesse trabalho era encontrar ao menos uma rede neural capaz de generalizar com sucesso o problema, os resultados ainda se mostram de grande valor, uma vez que tanto a Rede MLP quanto a Rede ELM foram capazes de gerar resultados abaixo dos 30% de *MAPE* esperados.

Também é possível ressaltar que, grande parte dos maiores erros percentuais de todas as redes neurais, é concentrada na região de menor resistência térmica (entre 0 e 1,2K/W). Isso pode muitas vezes ser explicado pelos baixos valores encontrados, uma vez que nesse caso, as variações no ambiente e todos os tipos de erro, como os de medição, tem uma maior influência no sistema e nos resultados obtidos. Os valores percentuais nessa região também representam menores erros absolutos, uma vez que 30% de erro para uma resistência térmica de 7K/W representa um valor absoluto muito maior que 30% de erro para uma resistência térmica de 0,5K/W, por exemplo.

Assim, é possível concluir que os resultados obtidos para os tubos de calor são também, muito representativos e mostram que as RNA têm capacidade de generalizar o problema proposto.

## 8 CONCLUSÃO

O presente estudo apresentou a avaliação da utilização de Redes Neurais Artificiais (RNA) para a determinação das resistências térmicas de termossifões e tubos de calor utilizando parâmetros de projeto. Para a formação dos bancos de dados necessários para a o treinamento das RNA foram utilizados estudos experimentais realizados anteriormente em termossifões e tubos de calor com mesmas dimensões. Foram testados separadamente termossifões e tubos de calor utilizando três diferentes RNA. As redes neurais utilizadas foram: *Perceptron* de Múltiplas Camadas (MLP); a Rede Função de Base Radial (RBF) e a Máquina de Aprendizado Extremo (ELM).

Inicialmente, foram realizadas as avaliações relativas ao banco de dados composto por termossifões. As entradas para as redes neurais foram: inclinação de trabalho, razão de preenchimento e potência dissipada, enquanto como saída foi esperada a resistência térmica do termossifão. As três redes neurais utilizadas apresentaram resultados próximos aos obtidos experimentalmente, se mostrando capazes de generalizar o problema. O menor erro foi atingido utilizando a Rede RBF, com um *MAPE* de 5,85%, enquanto as Redes ELM e MLP resultaram em um *MAPE* de 6,71% e 8,24% respectivamente.

Em seguida, os bancos de dados formados por tubos de calor com diferentes estruturas capilares foram avaliados. As entradas consideradas foram: tipo de estrutura capilar, razão de preenchimento, inclinação de trabalho e condutividade térmica efetiva calculada. A saída esperada era a resistência térmica do tubo de calor. As Redes ELM e MLP apresentaram resultados dentro do esperado, se mostrando capazes de generalizar o problema. O menor erro foi conseguido utilizando a Rede MLP com um *MAPE* de 13,96%, enquanto a Rede ELM obteve um valor de 25,74%. A Rede RBF apresentou resultados piores em relação às outras redes, com um *MAPE* de 67,03%.

Os resultados obtidos mostram que as RNA são capazes de gerar resultados muito próximos daqueles obtidos experimentalmente, sendo assim, podem ser utilizadas para a avaliação do comportamento térmico do termossifão antes mesmo da sua fabricação. Os erros obtidos em ambos os bancos de dados estão dentro de valores aceitáveis para os dispositivos avaliados, uma vez que esses funcionam com mudança de fase e convecção, o que geralmente implica em sistemas complexos.

Os resultados indicam que a utilização de RNA no auxílio de projetos térmicos de termossifões e tubos de calor pode ser benéfica, aumentando a assertividade na produção de protótipos, diminuindo o retrabalho e tempo necessário para a realização de estudos.

### **8.1 Sugestão para trabalhos futuros**

Dada a condição atual do desenvolvimento da utilização de RNA para avaliação do desempenho térmico de termossifões e tubos de calor, a presente Dissertação de Mestrado em Engenharia Mecânica representa o início desse tipo de estudo e, com isso, muitos aspectos podem ser explorados.

Como sugestão propõem-se:

- A avaliação de um banco de dados maior;
- O uso de novos tipos de estruturas capilares nos tubos de calor;
- A variação das dimensões dos termossifões e tubos de calor avaliados;
- O uso de diferentes fluidos de trabalho, tais como nanofluidos com diferentes composições e concentrações;
- O estudo de diferentes Redes Neurais Artificiais e/ou métodos de treinamento;
- O estudo de outros Métodos de Aprendizado de Máquina.

## REFERÊNCIAS

- AFFONSO, C. **Aplicação de Redes Neuro Fuzzy ao Processamento de Polímeros na Indústria Automotiva**. 2010. Dissertação (Mestrado) – Universidade Nove de Julho, Engenharia de Produção, São Paulo. 111 p.
- AGUIAR, V. M. **Influência da Razão de Preenchimento e da Inclinação no Desempenho Térmico de Termossifões**. 2016. 135 p. Trabalho de Conclusão de Curso (Graduação) - Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2016.
- AGUIAR, V. M. et al. Thermal analysis of a finned thermosyphon for heat exchanger applications. **International Journal of Advanced Engineering Research and Science**, v. 5, n. 1, p. 18-21, 2018.
- ANTONINI ALVES, T. KRAMBECK, L. SANTOS, P. H. D., 2018. Heat pipe and thermosyphon for thermal management of thermoelectric cooling. In: **Bringing thermoelectricity into reality**. London, UK: InTech, 2018. p. 353-373.
- ARAÚJO, L. N. *et al.* Ensemble method based on Artificial Neural Networks to estimate air pollution health risks. **Environmental Modelling and Software**, v. 123, p. 104567. 2020.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15220**: Desempenho térmico de edificações. Rio de Janeiro: ABNT, 2003. 8 p.
- BARBOSA G. N. N. *et al.* Segurança em redes 5g, Oportunidades e Desafios em Detecção de anomalias e previsão de tráfego baseadas em aprendizado de máquina, **XXI Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais**, 2021.
- BELOTTI, J. T *et al.* Neural-based ensembles and unorganized machines to predict streamflow series from brazilian hydroelectric plants. **Energies**, v. 13(18), p. 1-22. 2020.
- BERGMAN, T. L., LAVINE, S. A. **Incropera: fundamentos da transferência de calor e de massa**, 8 ed. LTC, Rio de Janeiro, 2019.
- BROST, O. **Closed Two Phase Thermosyphons, Class Notes**. EMC/UFSC Florianópolis, Brazil, 1996.
- BUSSE, C. A. Theory of the ultimate heat transfer limit of cylindrical heat pipes. **International Journal of Heat and Mass Transfer**, v. 16, n. 1, p. 169-186, 1973.
- CAMPOS, D. S. *et al.* Unorganized machines and linear multivariate regression model applied to atmospheric pollutants forecasting. **Acta Scientiarum. Technology**

(online), v. 42, p. e48203, 2020.

CHEN, R. H. *et al.* Prediction of CHF in concentric-tube open thermosiphon using artificial neural network and genetic algorithm. **Heat and Mass Transfer/Waerme- und Stoffuebertragung**, vol. 46, No. 3. pp. 345-353, 2010.

CHI, S. W. **Heat pipe theory and practice: a sourcebook**. Washington, D.C.: Hemisphere, 1976.

CULLEN, J. M., ALLWOOD, J. M. Theoretical efficiency limits for energy conversion devices, **Energy**, v. 35, p. 2059-2069, 2010.

CYBENKO, G. Aproximation by Superpositions of a Sigmoidal Function, Mathematics and Control, **Signals, and Systems**, Vol. 2. p. 303-314, 1989.

ÇENGEL, Y. A. **Termodinâmica**, 7. Ed, Porto Alegre, AMGH, 2013

DA SILVA, I. N., SPATTI, D. H., FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. Artliber, São Paulo, 2010.

DIMBARRE, V.V. *et al.* Investigação Experimental da Razão de Preenchimento de Termossifões Aplicados à Trocador de Calor. **Anais do XXVIII Congresso Nacional de Estudantes de Engenharia Mecânica**, Santa Maria, 2022.

DUARTE, J. B. **Introdução às inversas generalizadas de matrizes de aplicação comum em estatística experimental**, Taylor & Francis, 1996.

ELNAGGAR, Mohamed H.A. The Optimization of Thickness and Permeability of Wick Structure with Different Working Fluids of L-Shape Heat Pipe for Electronic Cooling. **Jordan Journal of Mechanical and Industrial Engineering**, v. 8, no. 3, p. 119-125, 2014.

FACELI, K., LORENA, A. C., GAMA, J., *et al.* **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2021.

FAGHRI, A., Heat Pipes: Review, Opportunities and Challenges. **Frontiers in Heat Pipes**, v. 5, 2014.

FAGHRI, A. **Heat Pipe Science and Technology**. Washington, DC, USA: Taylor & Francis, 1995.

FIORIN, D. V., *et al.* Aplicação de Redes Neurais e Previsões de Disponibilidade de Recursos Energéticos Solares. **Revista Brasileira de Ensino de Física**, v.33, 2011.

FRANCO, D., STEINER, M. Estudo comparativo de redes neurais artificiais para previsão de séries temporais financeiras. In: **Anais do XVII Simpósio de Pesquisa**

**Operacional e Logística da Marinha - SPOLM 2014.** São Paulo: Blucher, p. 303-313, 2014.

GROLL, M., & RÖSLER, S. Operation principles and performance of heat pipes and closed two-phase thermosyphons. **Journal of Non-Equilibrium Thermodynamics**, v. 17, p. 91-151, 1992.

HAKEEM, M. A., KAMIL, M., ARMAN, I. Prediction of temperature profiles using artificial neural networks in a vertical thermosiphon reboiler, **Applied Thermal Engineering**, v. 28, p. 1572-1579, 2008.

HUANG, G. B., ZHU, Q. Y., SIEW, C. K. Extreme learning machine: a new learning scheme of feedforward neural networks. In: **IEEE International Joint Conference on Neural Networks**, v. 2, p. 985–990, 2004.

HUANG, G. B., ZHU, Q. Y., SIEW, C. K. Extreme learning machine: theory and applications. **Neurocomputing**, v. 70, n. 1, p. 489–501, 2006

HAYKIN, S. **Neural networks and learning machines.** USA: Prentice Hall. 2008.

KAMIL, M., ALAM, S. S., ALI, H. Heat transfer to liquids in single vertical thermosiphon reboiler, **Experimental Thermal Fluid Science**. v. 10 p. 44–53, 1995.

KAMIL, M., SHAMSUZZOHA, M., ALAM, S. S. Effect of submergence on boiling incipience in a vertical thermosiphon reboiler, **International Journal of Thermal Sciences**. v. 44 p. 75-87, 2005.

KRAMBECK, Larissa. **Investigação experimental do desempenho térmico de telas metálicas em tubos de calor.** 2016. Trabalho de Conclusão de Curso em Engenharia Mecânica, Universidade Tecnológica Federal do Paraná, Ponta Grossa, PR, Brasil, 2016.

KRAMBECK, L. **Desempenho Térmico de Estruturas Capilares de Pó de Cobre Sinterizado em Tubos de Calor.** 2018. 155 p. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2018.

KACHBA, Y. *et al.* Artificial Neural Networks to estimate the influence of vehicular emission variables on morbidity and mortality in the largest metropolis in South America. **Sustainability**, v. 12(7), p. 2621, 2020.

KALOGIROU, S. A., SOFIA, P., ARGIRIS, D. Artificial neural networks used for the performance prediction of a thermosiphon solar water heater, **Renewable Energy**, v. 18, p. 87-99, 1999.

KALOGIROU S. A., SOFIA, P. Thermosiphon solar domestic water heating systems: Longterm performance prediction using artificial neural networks, **Solar Energy** v. 69, p. 163-174, 2000.

KASSOMENOS, P. *et al.* Identifying the contribution of physical and chemical stressors to the daily number of hospital admissions implementing an artificial neural network model. **Air Quality, Atmosphere & Health**, v. 4, p. 263–272, 2011.

KHALILI, M.; SHAFILI, M.B. Experimental and numerical investigation of the thermal performance of a novel sintered-wick heat pipe. **Applied Thermal Engineering**, v. 94, p. 59- 75, 2016.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**, 4. Ed São Paulo: Livraria da Física, 2006, 176p.

KUMAR C, H., SWAMY, R. P. (2021). Fatigue life prediction of glass fiber reinforced epoxy composites using artificial neural networks. **Composites Communications**, v. 26, p. 100812, 2021.

LIANG, F., GAO, J., XU, L. Thermal performance investigation of the miniature revolving heat pipes using artificial neural networks and genetic algorithms. **International Journal of Heat and Mass Transfer**, 151, p. 119394, 2020.

MACHADO, P. L. O. *et al.* Seleção de termossifões para aplicação em um sistema híbrido fotovoltaico/térmico. **Conjecturas**, v. 21, p. 47-58, 2021

MACHADO, P. L. O. **Sistema híbrido fotovoltaico/térmico para geração de energia elétrica e aquecimento de água utilizando termossifões**. Dissertação (Mestrado em Engenharia Mecânica), UTFPR, Ponta Grossa, 2022.

MACHADO, P. L. O. *et al.* Estimating Thermal Performance of Thermosyphons by Artificial Neural Networks. **Alexandria Engineering Journal**, v. 79, p. 93-104, 2023.

MANTELLI, M. B. H. **Curso sobre Tubos de Calor e Termossifões**, Notas de Aula. UFSC, Florianópolis, 2009;

MANTELLI, M. B. H. **Thermosyphons and Heat Pipes: Theory and Applications**. Springer International Publishing, 2021.

OLIVEIRA, M. A. C., **Redes Neurais de Hopfield Para Roteamento de Redes de Comunicação em FPGA**. 2016. 135 p. Trabalho de Conclusão de Curso (Graduação) - Universidade de Pernambuco, Recife, 2011.

MARTINIANO, A. *et al.* Utilizando uma rede neural artificial para aproximação da função de evolução do sistema de *Lorentz*. **Revista Produção e Desenvolvimento**, v. 2, p. 26-38, 2016.

MATTOS NETO, P. S. G. *et al.* Neural-based ensembles for particulate matter forecasting. **IEEE Access**, v. 9, p. 14470–14490, 2021.

MATTOS NETO, P. S. G. *et al.* A methodology to increase the accuracy of particulate matter predictors based on time decomposition. **Sustainability**, v. 12, p. 7310, 2020.

MCCULLOCH, W. S., PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943.

METAL POWDER INDUSTRIES FEDERATION, Standard 42: **Determination of Density of Compacted or Sintered Powder Metallurgy Products**, New Jersey, 1997.

NASCIMENTO, R. L. **Política de eficiência energética no Brasil**. Brasília. Consultoria Legislativa da Câmara dos Deputados, 2015.

NISHIDA, F. B. **Desenvolvimento de Tubos De Calor com Microranhuras Fabricadas por Eletroerosão a Fio**. 2016. 158 p. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2016.

NISHIDA, F.B. *et al.* Experimental investigation of heat pipe thermal performance with microgrooves fabricated by wire electrical discharge machining, **Thermal Science** v. 24, p. 701-711, 2020.

NIHALUDDIN, A. B. **Heat transfer to boiling liquids in a vertical tube thermosiphon reboiler**, M.E. Thesis, Department of Chemical Engineering., A.M.U. Aligarh, India, 1991.

PAOLINI, C., **Eragon**, New York: Alfred A. Knopf, 2003

PETERSON, G. P. **An introduction to heat pipes: modeling, testing, and applications**. Toronto, CA: JohnWiley & Sons, 1994.

POLEZER, G. *et al.* Assessing the impact of PM<sub>2.5</sub> on respiratory disease using artificial neural networks. **Environmental Pollution**, v. 235, p. 394-403, 2018.

RAJAB, R. H., AHMAD, H. H. Analysis of Thermosiphon Heat Pipe Performance Using an Artificial Neural Network, **Journal of The Institution of Engineers (India)**, v. 102, p. 243-255, 2021.

REAY, D. A., KEW, P. A., MCGLEN, R. J. **Heat Pipes: Theory, Design and Applications**. 6 ed. Waltham, MA, USA: Elsevier, 2014. 251p.

SALEHI, H., HERIS, S. Z., SALOOKI, M. K., NOEI, S. H. Designing a Neural Network for Closed Thermosyphon with Nanofluid Using a Genetic Algorithm. **Brazilian Journal of Chemical Engineering**, v. 28, p. 157-168, 2011.

SHABANY, Y. **Heat Transfer**, Thermal Management of Electronics. Boca Raton, FL, USA: CRC Press, 2010.

SHANBEDI, M. *et al.* Prediction of temperature performance of a two-phase closed thermosyphon using Artificial Neural Network. **Heat Mass Transfer**, v. 49, p. 65–73, 2013.

SIQUEIRA, H. *et al.* Selection of temporal lags for predicting riverflow series from hydroelectric plants using variable selection methods. **Energies**, v. 13, p. 4236, 2020.

SIQUEIRA, H. V. **Previsão de séries de vazões com redes neurais artificiais e modelos lineares ajustados por algoritmos bio-inspirados**, Orientador: Christiano Lyra Filho, Dissertação (Mestrado em Engenharia Elétrica), UNICAMP, Campinas, 2009.

SIQUEIRA P. T. *et al.* Influência da Inclinação no Desempenho Térmicos de Termossifões Aletados para Aplicação no Controle Térmico de Painéis Fotovoltaicos. In: **Anais do XXVII Congresso Nacional de Estudantes de Engenharia Mecânica**, Curitiba, 2020.

SMIL, V. **Energy: A beginner's guide**. Oneworld Publications. 2017.

SMIL, V. **Energy and civilization: A history**. MIT Press. Cambridge Massachusetts, London, UK. 2010.

SOUZA, J. **Análise em componentes principais**. v. 2. Brasília: Thesaurus. 67 p. 1988.

TAI, V. C. *et al.* Long-term electricity demand forecasting for Malaysia using artificial neural networks in the presence of input and model uncertainties. **Energy Engineering**, v. 118, p. 715–725, 2021.

TAI, V. C. *et al.* A novel power curve prediction method for horizontal-axis wind turbines using artificial neural networks. **Energy Engineering**, v. 118, p. 507–516, 2021.

TADANO, Y. S., SIQUEIRA, H., ANTONINI ALVES, T. Unorganized Machines to predict hospital admissions for respiratory diseases. In: **Proceedings of the 2016 IEEE Latin American Conference on Computational Intelligence**, LACCI 2016.

THE PERCEPTRON. **Towards: data science**, 29 jul. 2021. Disponível em: <https://towardsdatascience.com/the-perceptron-3af34c84838c> Acesso em: 10 dez de 2021.

WANG, X. *et al.* Predicting of thermal resistances of closed vertical meandering pulsating heat pipe using artificial neural network model. **Applied Thermal Engineering**, v. 149, p. 1134–1141, 2019.

WANG, X. *et al.* A general method to predict the performance of closed pulsating heat pipe by artificial neural network. **Applied Thermal Engineering**, v. 157, p. 113761, 2019.

YANG, X. YAN, Y.Y.; MULLEN, D. Recent Developments of Lightweight, High Performance Heat Pipes. **Applied Thermal Engineering**. V. 33-34, p.1-14, 2012.

## **APÊNDICE A – Dados utilizados (Termossifões)**

Configuração	Inclinação [°]	Razão de preenchimento [%]	Potência dissipada [W]	$R_{th}$ [°C/W]
#1	90	20	5	6,23
#2	90	20	10	6,14
#3	90	20	15	5,29
#4	90	20	20	4,10
#5	90	20	25	3,23
#6	90	20	30	2,51
#7	90	40	5	5,26
#8	90	40	10	5,17
#9	90	40	15	4,42
#10	90	40	20	3,23
#11	90	40	25	2,46
#12	90	40	30	1,94
#13	90	40	35	1,50
#14	90	40	40	1,25
#15	90	40	45	1,04
#16	90	60	5	6,46
#17	90	60	10	6,28
#18	90	60	15	4,37
#19	90	60	20	3,11
#20	90	60	25	2,28
#21	90	60	30	1,75
#22	90	80	5	5,88
#23	90	80	10	5,73
#24	90	80	15	3,97
#25	90	80	20	2,84
#26	90	80	25	2,16
#27	90	80	30	1,71
#28	90	100	5	5,46
#29	90	100	10	5,33
#30	90	100	15	4,09
#31	90	100	20	2,98
#32	90	100	25	2,29
#33	90	100	30	1,83
#34	45	20	5	6,19
#35	45	20	10	6,15
#36	45	20	15	5,07
#37	45	20	20	3,75
#38	45	20	25	2,89
Configuração	Inclinação [°]	Razão de preenchimento [%]	Potência dissipada [W]	$R_{th}$ [°C/W]
#39	45	20	30	2,26

<b>#40</b>	45	40	5	5,28
<b>#41</b>	45	40	10	5,24
<b>#42</b>	45	40	15	4,55
<b>#43</b>	45	40	20	3,30
<b>#44</b>	45	40	25	2,53
<b>#45</b>	45	40	30	1,98
<b>#46</b>	45	40	35	1,57
<b>#47</b>	45	40	40	1,27
<b>#48</b>	45	40	45	1,05
<b>#49</b>	45	60	5	6,17
<b>#50</b>	45	60	10	6,07
<b>#51</b>	45	60	15	4,24
<b>#52</b>	45	60	20	3,02
<b>#53</b>	45	60	25	2,21
<b>#54</b>	45	60	30	1,69
<b>#55</b>	45	60	35	1,36
<b>#56</b>	45	80	5	5,92
<b>#57</b>	45	80	10	5,85
<b>#58</b>	45	80	15	4,02
<b>#59</b>	45	80	20	2,86
<b>#60</b>	45	80	25	2,21
<b>#61</b>	45	80	30	1,77
<b>#62</b>	45	100	5	5,08
<b>#63</b>	45	100	10	4,82
<b>#64</b>	45	100	15	4,06
<b>#65</b>	45	100	20	2,94
<b>#66</b>	45	100	25	2,22
<b>#67</b>	45	100	30	1,72

## **APÊNDICE B – Dados utilizados (tubos de calor)**

Configuração	Tipo	$k_{eff}$	Inclinação [°]	Razão de preenchimento [%]	Potência dissipada [W]	$R_{th}$ [°C/W]
#1	1	2,38	0	60	5	5,66
#2	1	1,07	0	60	5	5,09
#3	1	1,61	0	60	5	1,22
#4	1	1,07	45	60	5	4,54
#5	1	1,61	45	60	5	1,66
#6	1	2,38	45	60	5	5,01
#7	1	2,38	90	60	5	5,10
#8	1	1,61	90	60	5	2,11
#9	1	1,07	90	60	5	4,79
#10	1	1,13	0	60	10	5,04
#11	1	2,60	0	60	10	5,44
#12	1	1,69	0	60	10	0,73
#13	1	2,49	45	60	10	5,23
#14	1	1,61	45	60	10	0,79
#15	1	1,13	45	60	10	4,70
#16	1	1,13	90	60	10	4,84
#17	1	1,69	90	60	10	0,92
#18	1	2,49	90	60	10	5,09
#19	1	1,17	0	60	15	4,07
#20	1	1,69	0	60	15	0,60
#21	1	2,70	0	60	15	4,16
#22	1	2,70	45	60	15	3,67
#23	1	1,17	45	60	15	3,63
#24	1	1,69	45	60	15	0,55
#25	1	1,17	90	60	15	3,68
#26	1	2,60	90	60	15	3,73
#27	1	1,69	90	60	15	0,62
#28	1	1,22	0	60	20	2,98
#29	1	1,76	0	60	20	0,55
#30	1	2,78	0	60	20	2,96
#31	1	2,78	45	60	20	2,55
#32	1	1,76	45	60	20	0,48
#33	1	1,22	45	60	20	2,55
#34	1	1,76	90	60	20	0,54
#35	1	1,22	90	60	20	2,60
#36	1	2,78	90	60	20	2,43
#37	1	1,28	0	60	25	2,14
#38	1	1,83	0	60	25	0,50
#39	1	2,88	0	60	25	2,12
#40	1	2,78	45	60	25	1,79

Configuração	Tipo	$k_{eff}$	Inclinação [°]	Razão de preenchimento [%]	Potência dissipada [W]	$R_{th}$ [°C/W]
#41	1	1,76	45	60	25	0,43
#42	1	1,25	45	60	25	1,78
#43	1	1,76	90	60	25	0,46
#44	1	2,78	90	60	25	1,68
#45	1	1,25	90	60	25	1,84
#46	1	1,28	0	60	30	1,72
#47	1	1,83	0	60	30	0,49
#48	1	2,88	0	60	30	1,62
#49	1	1,83	45	60	30	0,40
#50	1	2,83	45	60	30	1,29
#51	1	1,28	45	60	30	1,36
#52	1	1,28	90	60	30	1,45
#53	1	2,83	90	60	30	1,27
#54	1	1,83	90	60	30	0,44
#55	1	1,88	0	60	35	0,49
#56	1	1,30	0	60	35	1,32
#57	1	1,83	45	60	35	0,37
#58	1	2,88	45	60	35	1,03
#59	1	1,28	45	60	35	1,05
#60	1	1,88	90	60	35	0,41
#61	1	1,28	90	60	35	1,08
#62	1	2,88	90	60	35	0,94
#63	1	1,95	0	60	40	0,44
#64	1	1,88	45	60	40	0,35
#65	1	2,88	45	60	40	0,75
#66	1	1,91	90	60	40	0,38
#67	1	2,88	90	60	40	0,77
#68	1	1,30	90	60	40	0,89
#69	1	1,91	45	60	45	0,34
#70	1	1,95	90	60	45	0,37
#71	1	1,95	45	60	50	0,33
#72	2	1,48	0	60	5	6,93
#73	2	1,48	45	60	5	7,13
#74	2	1,48	90	60	5	6,94
#75	2	1,96	0	60	5	2,63
#76	2	1,96	45	60	5	2,43
#77	2	1,96	90	60	5	2,65
#78	2	1,48	0	60	10	6,61
#79	2	1,48	45	60	10	6,39
#80	2	1,48	90	60	10	6,44
#81	2	1,96	0	60	10	1,50
#82	2	1,96	45	60	10	1,28

Configuração	Tipo	$k_{eff}$	Inclinação [°]	Razão de preenchimento [%]	Potência dissipada [W]	$R_{th}$ [°C/W]
#83	2	1,96	90	60	10	1,36
#84	2	1,96	0	60	15	1,16
#85	2	1,96	45	60	15	0,89
#86	2	1,96	90	60	15	0,95
#87	2	1,48	0	60	15	4,49
#88	2	1,48	45	60	15	4,42
#89	2	1,48	90	60	15	4,36
#90	2	1,95	0	60	20	0,99
#91	2	1,96	45	60	20	0,76
#92	2	1,96	90	60	20	0,80
#93	2	1,48	0	60	20	3,14
#94	2	1,48	45	60	20	3,13
#95	2	1,48	90	60	20	3,06
#96	2	1,48	0	60	25	2,42
#97	2	1,48	45	60	25	2,48
#98	2	1,48	90	60	25	2,38
#99	2	1,95	0	60	25	0,85
#100	2	1,95	45	60	25	0,66
#101	2	1,95	90	60	25	0,71
#102	2	1,95	0	60	30	0,80
#103	2	1,95	45	60	30	0,59
#104	2	1,95	90	60	30	0,64
#105	2	1,48	0	60	30	1,89
#106	2	1,48	45	60	30	1,99
#107	2	1,48	90	60	30	1,91
#108	2	1,95	0	60	35	0,70
#109	2	1,95	45	60	35	0,50
#110	2	1,95	90	60	35	0,55
#111	2	1,95	0	60	40	0,67
#112	2	1,95	45	60	40	0,46
#113	2	1,95	90	60	40	0,52
#114	2	1,95	45	60	45	0,42
#115	2	1,95	90	60	45	0,47
#116	2	1,95	45	60	50	0,42
#117	3	1,94	0	60	5	3,48
#118	3	1,94	0	100	5	5,28
#119	3	1,94	45	100	5	4,89
#120	3	1,94	45	60	5	3,28
#121	3	1,94	90	60	5	3,35
#122	3	1,94	90	100	5	4,73
#123	3	1,94	0	120	5	5,21
#124	3	1,94	0	80	5	2,94

Configuração	Tipo	$k_{eff}$	Inclinação [°]	Razão de preenchimento [%]	Potência dissipada [W]	$R_{th}$ [°C/W]
#125	3	1,94	45	120	5	4,63
#126	3	1,94	45	80	5	3,06
#127	3	1,94	90	120	5	5,43
#128	3	1,94	90	80	5	2,93
#129	3	1,94	0	60	10	1,58
#130	3	2,03	0	100	10	2,60
#131	3	1,94	45	60	10	1,54
#132	3	1,94	45	100	10	2,41
#133	3	1,94	90	60	10	1,52
#134	3	2,03	90	100	10	2,21
#135	3	1,94	0	80	10	1,44
#136	3	2,03	0	120	10	2,65
#137	3	1,94	45	120	10	2,32
#138	3	1,94	45	80	10	1,49
#139	3	1,94	90	120	10	2,29
#140	3	1,94	90	80	10	1,43
#141	3	2,03	0	100	15	1,43
#142	3	2,03	0	60	15	1,03
#143	3	2,03	45	100	15	1,40
#144	3	2,03	45	60	15	1,00
#145	3	2,03	90	60	15	0,98
#146	3	2,03	90	100	15	1,38
#147	3	2,03	0	120	15	1,77
#148	3	2,03	0	80	15	1,12
#149	3	2,03	45	120	15	1,51
#150	3	2,03	45	80	15	1,02
#151	3	2,03	90	120	15	1,52
#152	3	2,03	90	80	15	1,01
#153	3	2,11	0	80	20	0,93
#154	3	2,03	0	60	20	0,81
#155	3	2,11	0	120	20	1,37
#156	3	2,11	0	100	20	1,24
#157	3	2,03	45	120	20	1,16
#158	3	2,11	45	100	20	1,04
#159	3	2,03	45	60	20	0,77
#160	3	2,03	45	80	20	0,78
#161	3	2,03	90	80	20	0,80
#162	3	2,11	90	120	20	1,18
#163	3	2,03	90	60	20	0,74
#164	3	2,11	90	100	20	1,05
#165	3	2,11	0	60	25	0,73
#166	3	2,11	0	120	25	1,17

Configuração	Tipo	$k_{eff}$	Inclinação [°]	Razão de preenchimento [%]	Potência dissipada [W]	$R_{th}$ [°C/W]
#167	3	2,11	0	100	25	1,03
#168	3	2,11	0	80	25	0,81
#169	3	2,11	45	60	25	0,67
#170	3	2,11	45	80	25	0,69
#171	3	2,11	45	100	25	0,84
#172	3	2,11	45	120	25	0,97
#173	3	2,11	90	80	25	0,69
#174	3	2,11	90	100	25	0,84
#175	3	2,11	90	120	25	1,00
#176	3	2,11	90	60	25	0,64
#177	3	2,18	0	60	30	0,68
#178	3	2,18	0	100	30	0,96
#179	3	2,18	0	120	30	1,05
#180	3	2,18	0	80	30	0,74
#181	3	2,11	45	80	30	0,63
#182	3	2,18	45	60	30	0,62
#183	3	2,11	45	120	30	0,87
#184	3	2,18	45	100	30	0,71
#185	3	2,18	90	120	30	0,88
#186	3	2,11	90	80	30	0,63
#187	3	2,18	90	60	30	0,59
#188	3	2,18	90	100	30	0,73
#189	3	2,18	0	120	35	0,93
#190	3	2,18	45	120	35	0,79
#191	3	2,18	90	120	35	0,79
#192	3	2,18	0	80	35	0,70
#193	3	2,18	0	100	35	0,85
#194	3	2,18	45	80	35	0,59
#195	3	2,18	45	100	35	0,62
#196	3	2,18	90	100	35	0,65
#197	3	2,18	90	80	35	0,59
#198	3	2,18	0	60	35	0,65
#199	3	2,18	45	60	35	0,58
#200	3	2,18	90	60	35	0,53
#201	3	2,25	0	80	40	0,65
#202	3	2,25	45	80	40	0,55
#203	3	2,25	90	80	40	0,56
#204	3	2,25	0	100	40	0,78
#205	3	2,25	0	60	40	0,62
#206	3	2,25	0	120	40	0,91
#207	3	2,25	45	60	40	0,54
#208	3	2,25	45	100	40	0,56

<b>Configuração</b>	<b>Tipo</b>	<b><math>k_{eff}</math></b>	<b>Inclinação [°]</b>	<b>Razão de preenchimento [%]</b>	<b>Potência dissipada [W]</b>	<b><math>R_{th}</math> [°C/W]</b>
<b>#209</b>	3	2,18	45	120	40	0,74
<b>#210</b>	3	2,25	90	60	40	0,50
<b>#211</b>	3	2,25	90	120	40	0,72
<b>#212</b>	3	2,25	90	100	40	0,62
<b>#213</b>	3	2,25	0	100	45	0,69
<b>#214</b>	3	2,25	45	80	45	0,52
<b>#215</b>	3	2,25	45	100	45	0,54
<b>#216</b>	3	2,25	90	60	45	0,47
<b>#217</b>	3	2,25	90	80	45	0,51
<b>#218</b>	3	2,25	90	100	45	0,60