

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

**MIGUEL CELANO MENEZES DE ALMEIDA
VINICIUS SYLVESTRE SIMM**

**MÉTODO DE OTIMIZAÇÃO DE DISSIPADORES DE CALOR
ALETADOS UTILIZANDO INTELIGÊNCIA COMPUTACIONAL**

PONTA GROSSA

2022

MIGUEL CELANO MENEZES DE ALMEIDA ✉

VINICIUS SYLVESTRE SIMM ✉

MÉTODO DE OTIMIZAÇÃO DE DISSIPADORES DE CALOR ALETADOS UTILIZANDO INTELIGÊNCIA COMPUTACIONAL

FINNED HEAT SINK OPTIMIZATION METHOD WITH THE USE OF COMPUTATIONAL INTELLIGENCE

Trabalho de Conclusão de Curso apresentado como requisito para obtenção do título de Bacharel/Bacharel em Engenharia Mecânica da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. Thiago Antonini
Alves ✉ 

PONTA GROSSA

2022



Este Trabalho de Conclusão de Curso está licenciado sob uma Licença Creative Commons Atribuição 4.0 Internacional.

**MIGUEL CELANO MENEZES DE ALMEIDA
VINICIUS SYLVESTRE SIMM**

**MÉTODO DE OTIMIZAÇÃO DE DISSIPADORES DE CALOR ALETADOS
UTILIZANDO INTELIGÊNCIA COMPUTACIONAL**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título de
Bacharel em Engenharia Mecânica da Universidade
Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 29/junho/2022

Thiago Antonini Alves
Doutor em Engenharia Mecânica
Universidade Tecnológica Federal do Paraná – Ponta Grossa

Hugo Valadares Siqueira
Doutor em Engenharia Elétrica
Universidade Tecnológica Federal do Paraná – Ponta Grossa

Luiz Eduardo Melo Lima
Doutor em Engenharia Mecânica
Universidade Tecnológica Federal do Paraná – Ponta Grossa

PONTA GROSSA

2022

RESUMO

Com os avanços tecnológicos dos últimos anos, equipamentos eletroeletrônicos se tornaram mais rápidos, incorporaram maiores funcionalidades e seus tamanhos foram reduzidos drasticamente, acarretando no aumento da densidade de potência e no fluxo de calor em seus componentes. Para manter a temperatura de operação desses equipamentos em níveis aceitáveis, sem o comprometimento da segurança e confiabilidade, a utilização de dissipadores de calor aletados é essencial. Neste contexto, realizou-se no presente Trabalho um estudo teórico-numérico de otimização sobre o impacto que variáveis geométricas como altura, espessura e número de aletas planas representam no desempenho térmico de dissipadores de calor aletados utilizados no resfriamento de eletroeletrônicos. Para realizar a análise, uma configuração de um dissipador de calor de aletas planas foi validado junto a dados experimentais disponíveis na literatura e o método *Generalized Subset Design* (GSD) de Planejamento de Experimentos (DOE - *Design of Experiment*) foi utilizado na seleção dos cenários simulados, visando a obtenção de um banco de dados com menor custo computacional. Todos esses cenários foram simulados utilizando o programa comercial de Dinâmica dos Fluidos Computacional (CFD - Computational Fluid Dynamics) e os resultados foram utilizados para treinar modelos de aprendizado de máquina, desenvolvidos na linguagem de programação aberta Python, com o propósito de estimar os resultados de desempenho térmico dos dissipadores de calor aletados. Os modelos selecionados foram do tipo árvore de decisão, regressão por vetores suporte, perceptron de múltiplas camadas e redes neurais desenvolvidas a partir do zero utilizando o *Keras*. Uma análise teórica de cada variável foi efetuada e seus impactos em cada um dos resultados monitorados foi apresentada de forma gráfica. Foi possível constatar que tanto o número de aletas quanto a espessura dessas possuem valores ótimos, fora dos extremos estabelecidos, apresentando um comportamento não-linear. Os modelos preditivos de aprendizado de máquina foram empregados para detectar os padrões apresentados por cada variável e calcular o efeito desses parâmetros geométricos no desempenho térmico dos dissipadores de calor aletados.

Palavras-chave: dissipador de calor; otimização de geometria; aprendizado de máquina.

ABSTRACT

With the technological advancement of the latest years, electrical and electronic equipments have become ever faster, incorporating new functions and drastically reducing its size, leading to higher power density and heat flux in its components. To keep the operation temperature of these equipments within acceptable levels, without compromising safety nor reliability, the use of finned heat sinks is essential. Within this context, in this Thesis was realized a theoretical numerical optimization analysis on the impact of geometric variables such as the height, width and number of straight fins on the thermal performance of finned heat sinks used in the cooling of electrical and electronic equipment. For this analysis, a setup for a straight fins heat sink was validated with experimental data available in the literature and the Generalized Subset Design (GSD) method of Design of Experiment (DOE) was used in the selection of scenarios to be simulated in order to obtain a data bank with lower computational cost. All these cases were simulated using a commercial Computational Fluid Dynamics (CFD) software, and the results were used in training Machine Learning models, using the open source development language Python, with the purpose of predicting the thermal performance results of finned heat sinks. The models chosen were the decision tree and support vector regressors, multilayer perceptron and neural network developed from the ground up using Keras. A theoretical analysis of each variable was done and its impacts in each of the tracked results were presented in graphical form. It was found that the number and width of fins has a middle optimal value, between the set extreme points, showing a non-linear behavior. The prediction Machine Learning models were applied in the detection of behavior patterns of each variable and calculation of the effect such geometric parameter have in the thermal performance of finned heat sinks.

Keywords: heat sink; geometry optimization; machine learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Visão lateral e frontal do aparato experimental utilizado em Das e Dwivedi (2013)	12
Figura 2 – Desenho técnico do dissipador de calor usado na validação, medidas em [mm]	20
Figura 3 – Desenho técnico do dissipador de calor usado na validação, medidas em [mm]	20
Figura 4 – Seção de testes do aparato experimental utilizado em Maschietto (2018)	21
Figura 5 – Seleção das combinações a serem simuladas por abordagem geométrica	23
Figura 6 – Modelo construído no programa Ansys/Fluent	23
Figura 7 – Modelo 3D dos dissipadores de calor utilizados na geração do banco de dados	28
Figura 8 – Análise de refinamento de malha	29
Figura 9 – Grade computacional 3D não-uniforme utilizada nas simulações numéricas - perspectiva 3D	30
Figura 10 – Detalhe da grade computacional em uma seção transversal próxima ao dissipador de calor aletado	31
Figura 11 – Distribuição de temperaturas no dissipador de calor aletado considerando diferentes condições de escoamento	31
Figura 12 – Comparação da temperatura máxima dos dissipadores de calor aletados em função do número de Reynolds	32
Figura 13 – Comparação do número de Nusselt em função do número de Reynolds	33
Figura 14 – Perfis de velocidade do escoamento de ar sobre o dissipador de calor aletado no plano yz - Casos A, E e G	35
Figura 15 – Contorno de temperatura do ar - Casos A, E e G	36
Figura 16 – Efeito das variáveis geométricas na temperatura máxima	38
Figura 17 – Efeito das variáveis geométricas no Número de Nusselt	38
Figura 18 – Efeito das variáveis geométricas na resistência térmica	39
Figura 19 – Variações dos modelos para o número de Nusselt	41
Figura 20 – Variações dos modelos para o número de Nusselt de forma individual	42
Figura 21 – Variações dos modelos para a temperatura máxima	42
Figura 22 – Variações dos modelos para a temperatura máxima de forma individual	42
Figura 23 – Variações dos modelos para a resistência térmica	43
Figura 24 – Variações dos modelos para a resistência térmica de forma individual	43
Figura 25 – Erro Médio Quadrado para o número de Nusselt em relação às épocas	43
Figura 26 – Erro Médio Quadrado para a Resistência Térmica em relação às épocas	44
Figura 27 – Erro Médio Quadrado para a Temperatura Máxima em relação às épocas	44

LISTA DE TABELAS

Tabela 1 – Configurações do DOE	22
Tabela 2 – Combinações de geometria dos cenários DOE/GSD para geração do banco de dados	24
Tabela 3 – Combinações de geometria dos cenários para validação e testes dos algoritmos de Aprendizado de Máquina	25
Tabela 4 – Dados da análise de refinamento de malha	29
Tabela 5 – Comparações de temperaturas máximas entre as simulações numéricas e os dados experimentais de Maschietto (2018)	32
Tabela 6 – Comparações do número de Nusselt entre as simulações numéricas e os dados experimentais de Maschietto (2018)	33
Tabela 7 – Valores encontrados para os índices de desempenho dos casos . .	37
Tabela 8 – Previsões da temperatura máxima [°C] para cada modelo	40
Tabela 9 – Previsões do Número de Nusselt para cada modelo	40
Tabela 10 – Previsões da resistência térmica [°C/W] para cada modelo	41
Tabela 11 – Valor p para cada caso e variável de saída	45
Tabela 12 – R-quadrado por modelo por variável de saída	46
Tabela 13 – Importância das variáveis	46

SUMÁRIO

1	INTRODUÇÃO	8
1.1	JUSTIFICATIVA	9
1.2	OBJETIVOS	9
1.3	DESCRIÇÃO DO TRABALHO	10
2	FUNDAMENTAÇÃO TEÓRICA COM REVISÃO DE LITERATURA	11
2.1	OTIMIZAÇÃO DE ALETAS	11
2.2	PLANEJAMENTO DE EXPERIMENTOS	13
2.3	MODELOS PREDITIVOS E PYTHON	14
2.3.1	<i>Decision Tree Regressor</i>	15
2.3.2	<i>Random Forest Regressor</i>	15
2.3.3	Regressão Linear	15
2.3.4	Máquinas de Vetores Suporte	16
2.3.5	<i>Perceptron</i> Múltiplas Camadas	16
2.3.6	Aprendizado Profundo	17
2.3.7	Normalização de Intervalos	17
2.3.8	Métrica R-Quadrado	18
2.3.9	Análise de Normalidade da Amostra	18
3	METODOLOGIA	19
3.1	CRIAÇÃO DO DOE	21
3.2	MODELAGEM CFD	22
3.3	GERAÇÃO DO BANCO DE DADOS	24
3.4	TREINAMENTO DE MODELOS PREDITIVOS	25
4	RESULTADOS E DISCUSSÃO	27
4.1	SIMULAÇÕES NUMÉRICAS	27
4.1.1	Validação da Modelagem CFD	27
4.1.2	Simulação Numérica dos Cenários para Geração do Banco de Dados	33
4.2	ANÁLISE PELO MÉTODO DE PLANEJAMENTO DE EXPERIMENTOS	34
4.3	MODELOS DE APRENDIZADO DE MÁQUINA	39
5	CONCLUSÕES	47
	REFERÊNCIAS	50
	ANEXO A – LEI N.º 9.610, DE 19 DE FEVEREIRO DE 1998: DIREITOS AUTORAIS / DISPOSIÇÕES PRELIMINARES	53

1 INTRODUÇÃO

Dissipadores de calor aletados são dispositivos trocadores de calor constituídos por um conjunto de aletas, essenciais em inúmeros componentes eletroeletrônicos como forma de aumentar a vida útil e melhorar sua eficácia, reduzindo a temperatura do componente e trazendo-o para dentro da faixa ideal de operação.

Esses trocadores de calor podem ser encontrados desde circuitos para iluminação com LED, de tamanho menor e utilizando apenas ventilação natural, até no resfriamento de processadores de computador, placas gráficas e diodos laser, utilizando desde ventilação forçada até refrigeração à água ou fluido dielétrico (ÇENGEL; GHAJAR, 2012).

Dentre os fatores que afetam o desempenho de dissipadores de calor aletados estão a velocidade do ar, material utilizado e a configuração das aletas - geometria, área da seção transversal e proximidade das aletas - além do uso de materiais de interface térmica, importante para redução da resistência térmica de contato entre o dissipador de calor aletado e o componente eletroeletrônico (ALVES; ALTEMANI, 2012).

Na execução de simulações numéricas envolvendo o problema de resfriamento de componentes eletroeletrônicos, pode-se utilizar programas de Dinâmica dos Fluidos Computacional (CFD - *Computational Fluid Dynamics*). Tais programas utilizam o método de Volumes Finitos (PATANKAR, 1980), sendo um deles o Ansys[®]/Fluent[®].

Diversas metodologias já foram empregadas para tentar resolver problemas da área termica. Uma tecnologia que pode ser utilizada é a de redes neurais artificiais. Em Silva, Flauzino e Spatti (2010), os autores discorrem sobre esse tema e sobre a aplicação destas redes em segmentos distintos, apresentando os princípios teóricos de cada modelo e aplicações possíveis. Dentre essas, estão ferramentas para identificar padrões em sistemas, análise de distúrbios em energia elétrica, classificação de alimentos com visão computacional e até otimizadores para luzes de freio em veículos automotores.

Além de redes neurais, modelos de Aprendizado de Máquina de regressão podem ser empregados para resolução de problemas nas mais diversas áreas. Um dos métodos amplamente implementados é o da Regressão Linear. Como explicado por Boyd e Sun (2021), esse método pode ser utilizado na descrição de eventos, na previsão de uma determinada variável e até em inferências. De forma mais avançada, modelos de Aprendizado de Máquina, como modelos de árvore de decisão, regressões

lineares, máquinas de vetores suporte e *perceptron* de multiplas camadas, podem ser treinados para criar modelos de estimação.

Diversas bibliotecas públicas fornecem ferramentas para gerar tais modelos. Dessas biblioteca, muitas podem ser encontradas para a linguagem de programação Python, tanto no ambiente da indústria como no campo técnico-científico. Python é uma linguagem de programação de fácil aprendizado, utilizada amplamente e conta com uma grande base de usuários no mundo. Algumas das aplicações tangem às áreas de Aprendizado de Máquina, tanto supervisionado quanto não supervisionado, e análise estatística, sendo orientada à tarefa porém de fácil comparação entre diferentes métodos empregados, como apresentado em Geron (2019).

1.1 JUSTIFICATIVA

Com o avanço tecnológico, os componentes eletroeletrônicos apresentam uma tendência no aumento de desempenho com redução significativa do seu tamanho e peso. Dessa forma são necessários sistemas de resfriamento capazes de lidar com fluxo de calor maior e espaço disponível limitado. Tais exigências acarretam na necessidade de entender quais características do sistema devem ser focadas durante processos de otimização.

Maschietto (2018) avaliou computacionalmente dissipadores de calor com aletas planas, analisando a melhor configuração dentre algumas propostas. A comparação dos resultados dele com os de Yang *et al.* (2017), Das e Dwivedi (2013) e Pakrouh *et al.* (2015) mostra que a variação das características de escoamento e geométricas do sistema alteram muito o resultado obtido em estudos de otimização, esses sendo custosos na obtenção de dados experimentais e subsequente otimização numérica. O desenvolvimento de métodos de avaliação mais eficientes é, por tanto, muito valioso pelo seu potencial de redução de custo e tempo.

1.2 OBJETIVOS

O objetivo geral deste trabalho é realizar um estudo teórico-numérico de otimização geométrica de dissipadores de calor aletados aplicados no resfriamento de componentes eletroeletrônicos utilizando diferentes modelos de Aprendizado de Má-

quina.

Os objetivos específicos desse Trabalho são:

- Definir as variáveis geométricas do dissipador de calor aletado mais relevantes.
- Definir as combinações de parâmetros que serão estudadas através de Planejamento de Experimentos (DOE - *Design of Experiments*).
- Obter banco de dados por meio de simulação numérica utilizando o programa de CFD Ansys/Fluent.
- Treinar modelos de Aprendizado de Máquina para prever os resultados.
- Avaliar os erros obtidos pelos modelos de Aprendizado de Máquina.

1.3 DESCRIÇÃO DO TRABALHO

Neste Capítulo 1 apresentam-se uma introdução ao tema, a justificativa para realização do trabalho e os objetivos do estudo.

O Capítulo 2 contém uma fundamentação teórica, incluindo temas de otimização de dissipadores de calor aletados, conceitos de Planejamento de Experimentos e modelos de previsão por Aprendizado de Máquina.

A metodologia está contida no Capítulo 3. Nessa parte, foram mencionados os detalhes do processo de criação do DOE, as características e a fonte de dados utilizados na validação da modelagem numérica, as características do programa comercial de CFD utilizado para as simulações numéricas, as equações governantes e os modelos utilizados, os valores para cada geometria simulada e maiores detalhes quanto ao treinamento dos modelos preditivos escolhidos.

Os resultados obtidos estão apresentados no Capítulo 4, iniciando com as validações de modelagem CFD e demonstrando o modelo tridimensional (3D) de todas as geometrias avaliadas. Também se encontram as demonstrações e discussões dos valores e das características resultantes das simulações numéricas e a geração do banco de dados. Feito isso, são discutidos resultados do DOE, considerando as variáveis geométricas e a representatividade de cada para os indicadores de desempenho, conforme os dados do banco gerado. Finalmente, o resultado do treinamento e testes dos modelos de Aprendizado de Máquina são expostos e analisados.

No Capítulo 5, são apresentadas as conclusões das análises desse trabalho.

2 FUNDAMENTAÇÃO TEÓRICA COM REVISÃO DE LITERATURA

Nesta seção são embasados conceitos de otimização de aletas, Planejamento de Experimentos e modelos preditivos.

2.1 OTIMIZAÇÃO DE ALETAS

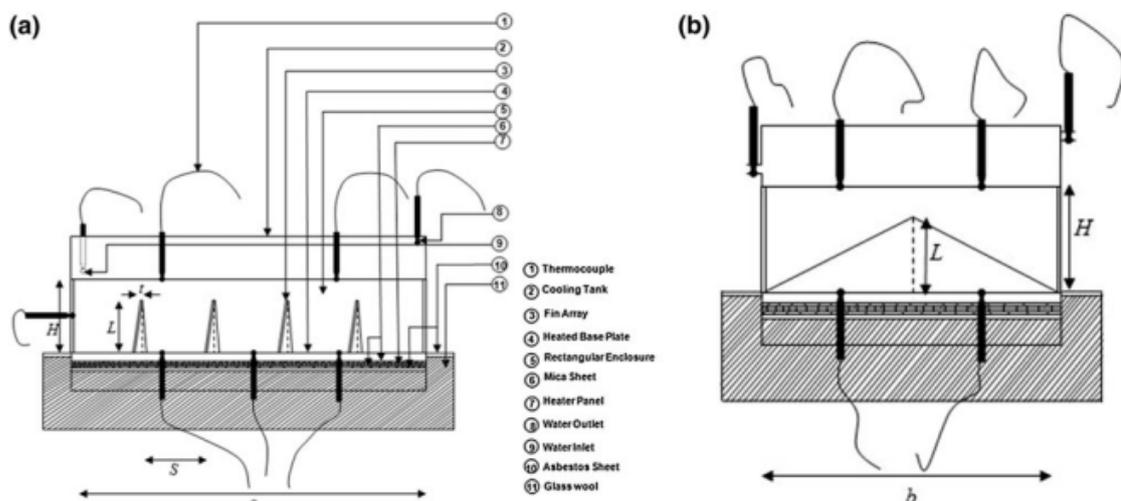
Os dissipadores de calor aletados são trocadores de calor constituídos por um conjunto de aletas que são empregados no resfriamento de componentes eletroeletrônicos. Na otimização de aletas desses dissipadores de calor, encontram-se também análises voltadas para outras características geométricas do conjunto, avaliando seu impacto na taxa de transferência de calor total (ALVES; ALTEMANI, 2012). Há diversos trabalhos na literatura sobre a contribuição de certas características na efetividade de dissipadores de calor aletados, utilizando métodos de simulação numérica e análise experimental, alterando o sistema e comparando os resultados.

Yang *et al.* (2017) abordaram a diferença entre conjuntos de aletas com pinos de características geométricas distintas. De forma a alterar apenas uma característica geométrica, eles mantiveram a área da seção transversal constante, com a mesma disposição entre as aletas e a mesma altura, mudando apenas a forma geométrica das aletas. Os parâmetros obtidos para comparar o desempenho dos conjuntos foram: temperatura máxima atingida, queda de pressão na entrada e saída, resistência térmica e um coeficiente que relaciona a temperatura máxima, mínima e média. As variações de seção transversal escolhidas foram: triangular, quadrada, pentagonal, hexagonal e circular. Os resultados das simulações numéricas desse estudo apontaram uma menor temperatura máxima para as aletas hexagonais, enquanto as aletas triangulares apresentam as maiores temperaturas máximas e as maiores queda de pressão. Yang *et al.* (2017) também apontaram a menor resistência ao escoamento no conjunto de aletas circulares. Uma explicação proposta para a menor eficiência na transferência de calor por parte das aletas triangulares foi a presença de vórtices atrás dessas aletas.

Das e Dwivedi (2013) apresentaram uma abordagem considerando o número de Rayleigh, altura e espaçamento de aletas. Destaca-se nesse trabalho o uso de diferentes métodos de DOE, contrastando o uso do método Fatorial Completo com o método de Taguchi (KARNA; SAHAI *et al.*, 2012), utilizando dados experimentais. Os

resultados do uso do método Fatorial Clássico, com 27 rodadas experimentais, foram equivalentes à conclusão com o método de Taguchi, com 9 rodadas, mostrando uma eficiência maior na definição dimensional utilizando o segundo método. Além disso, não foi possível a criação de um modelo matemático ou de regressão usando a redução do método de Taguchi, pois o mesmo entrega os parâmetros ideais de forma direta, enquanto o método Fatorial entrega todos os dados de combinação de fatores de forma não-trabalhada, podendo ser alimentado à métodos de regressão com maior facilidade. Quanto aos fatores, foi possível determinar uma equação para o número de Nusselt do sistema, concluindo que o aumento no número de Rayleigh e da altura L da aleta é positivo. No entanto, a redução da distância S entre aletas possui um efeito inicialmente positivo, devido ao aumento de área de troca de calor, mas em certo ponto é vencido pelo efeito negativo que a interferência entre as camadas-limite apresenta. O sistema estudado por Das e Dwivedi (2013) pode ser visto na Figura 1.

Figura 1 – Visão lateral e frontal do aparato experimental utilizado em Das e Dwivedi (2013)



Fonte: Das e Dwivedi (2013).

Pakrouh *et al.* (2015) estudaram o efeito de diferentes características no desempenho de um conjunto aletado. Nesse trabalho, quatro variáveis foram elencadas: quantidade de aletas em uma área de tamanho fixo, espessura da aleta, altura da aleta e espessura da base. Contudo, eles mostraram que a contribuição dessa última variável é desprezível se comparado às demais. Esse estudo difere de anteriores ao utilizar um material de mudança de fase (PCM - Phase Change Material) entre as aletas, analisando a contribuição das variáveis geométricas na transição de fase do PCM. É relevante apontar que, com as variáveis "número de aletas" e "espessura da

aleta", foi possível relacionar a fração da área transversal ocupada por aletas, ou seja, a densidade de aletas.

Maschietto (2018) utilizou resultados experimentais e de simulações numéricas para executar um estudo de otimização de dissipadores de calor com aletas planas em situação de convecção forçada. Em seu estudo, foram feitos três casos de otimização para um dissipador de calor com tamanho fixo da base. Nesses cenários de alteração da geometria, foram utilizados valores de número de Reynolds diferentes, indicando os melhores valores dimensionais em termos de diferentes velocidades do ar. O primeiro caso de otimização foi apenas para aumentar a altura das aletas, resultando em uma menor temperatura para o dissipador de calor de maior altura, independente do número de Reynolds. O segundo caso foi para alterar o número de aletas sem mudar a altura das mesmas, mostrando que o número ótimo de aletas é menor quando o número de Reynolds é baixo e maior quando o número de Reynolds é mais alto. O último caso foi para alterar número e altura das aletas de forma que a área da superfície fosse constante, indicando que um menor número de aletas mais altas é preferível.

2.2 PLANEJAMENTO DE EXPERIMENTOS

A proposta de utilizar a metodologia conhecida como *Design of Experiments* (DOE, ou Planejamento de Experimentos em português) em conjunto com algoritmos de Aprendizado de Máquina foi feita e analisada em diversos trabalhos. Lujan-Moreno *et al.* (2018) introduziram os benefícios e as aplicações do DOE. A metodologia envolve selecionar as variáveis, seus limites e o número de combinações a serem feitas. É amplamente empregada pelo benefício de entender o efeito combinado de variáveis, ao contrário de isolar uma única variável, mantendo as outras constantes.

O tipo mais básico de DOE é a combinação de variáveis com dois fatores cada. Contudo, é observável que o número de experimentos cresce de forma exponencial a cada nova variável k estudada, ou seja, a quantidade de combinação é igual a 2^k . Quando um grupo de combinações se torna muito grande e, por algum motivo, inviável de se testar, existe a possibilidade de se reduzir as combinações. Porém, pode haver um impacto na precisão dos resultados obtidos, consequentemente.

Um novo modelo foi proposto por Surowiec *et al.* (2017) para realizar combinações fatoriais fracionadas e reduzir o número de combinações necessárias. Esse

modelo chamado de *Generalized Subset Design* (GSD), está disponível para a linguagem de programação Python na biblioteca pyDOE2, na versão 1.1. O modelo é especialmente útil para problemas com mais de dois níveis, ou seja, mais de duas variações para cada variável.

Outro método para reduzir o número de combinações é denominado *Box-Behnken Design* (BBD), que é apresentado em Ferreira *et al.* (2007). Esse modelo é composto por "experimentos de segunda ordem giratórios ou quase giratórios baseado em um experimento fatorial incompleto de três níveis", como especificado no próprio trabalho. Em representação gráfica, três variáveis se traduziriam em três eixos de um cubo, e cada aresta sendo representada por um ponto, e um ponto adicional no centro do cubo.

2.3 MODELOS PREDITIVOS E PYTHON

Python é uma das linguagens de programação mais utilizadas no mundo (CASS, 2018) e cada vez ganha mais espaço nos mais diferentes setores. Diversas bibliotecas estão disponíveis de forma pública na internet para complementar as funcionalidades da linguagem e algumas delas possuem ampla utilidade em aplicações estatísticas. Duas bibliotecas em especial para tais fins são: *Statsmodels* e *Scikit-Learn*.

A biblioteca *Statsmodels* agrega funções que realizam o procedimento estatístico para o usuário. Essa biblioteca possui métodos de Regressão Linear, modelos Lineares Generalizados, entre outros, que requerem o conjunto de dados a ser trabalhado como entrada (SEABOLD; PERKTOLD, 2010).

A biblioteca *Scikit-Learn* possui algoritmos de Aprendizado de Máquina para problemas de média escala. O pacote tem como objetivo levar esses recursos para não-especialistas utilizando linguagens de programação de fácil uso, bom desempenho, com documentação e consistência. O Pacote *Scikit-Learn* apresenta funções para dividir o conjunto de dados em grupos de treino e teste, correlação entre variáveis, além de diversos métodos de treino. Esses abrangem desde modelos de Regressão Linear à Redes Neurais Artificiais, como o *Perceptron* Múltiplas Camadas (PEDREGOSA *et al.*, 2011).

2.3.1 *Decision Tree Regressor*

As árvores de decisão geradas pelos modelos *Decision Tree*, presentes na biblioteca *Scikit-Learn*, são métodos de aprendizado supervisionados não-paramétricos. Como apontado na documentação do modelo, as árvores de decisão podem ser detalhadas e os nós, ou as fronteiras de decisão, podem ser estudadas individualmente. Esse modelo possui duas vertentes: regressão e classificação. Sendo a primeira de grandeza numérica e a segunda representada por classes. No modelo de regressão, algumas das variáveis, também chamadas de hiper parâmetros, empregadas para a construção da árvore são: critério para medir as divisões de dados, quantidade máxima de níveis da árvore, quantidade mínima de dados para realizar uma subdivisão, o número mínimo de dados em cada folha, entre outros.

2.3.2 *Random Forest Regressor*

O modelo *Random Forest Regressor*, também presente na biblioteca *Scikit-Learn*, parte do mesmo princípio que o modelo anterior, porém acrescenta aleatoriedade na construção de diversos modelos. Os resultados individuais de cada modelo são utilizados para calcular uma média, que é utilizada como resposta do modelo final. Esse modelo pode ser visto como uma generalização do modelo tradicional de árvores de decisão, reduzindo a chance de sobreajuste. Dentre outros, um parâmetro adicional é o número de árvores a serem treinadas para a constituição do modelo *Random Forest Regressor*.

2.3.3 Regressão Linear

O modelo de Regressão Linear disponibilizado na biblioteca *Scikit-Learn* utiliza o Método dos Mínimos Quadrados, que consiste no cálculo de uma reta que minimize a soma dos quadrados residuais entre os dados fornecidos e a reta calculada. O ajuste da reta ocorre por meio da Equação (2), buscando os coeficientes (w) que resultem no menor valor possível:

$$\min_w \|Xw - y\|_2^2 \quad (1)$$

2.3.4 Máquinas de Vetores Suporte

O modelo *Support Vector Machine*, ou Máquinas de Vetores Suporte, disponibilizado pela biblioteca *Scikit-Learn*, trabalha com classificações, regressões e detecção de valores atípicos em um processo de aprendizado supervisionado. Os cálculos para o modelo são expostos por Chang e Lin (2011). Dentre os parâmetros alteráveis para o treinamento do modelo estão: parâmetro de regularização (C), sendo inversamente proporcional à severidade da regularização, e ε que representa os limites da região em que nenhuma punição é aplicada na função de perda.

2.3.5 *Perceptron* Múltiplas Camadas

Como detalhado por Taud e Mas (2018), o Método *Perceptron* Múltiplas Camadas (MLP, do inglês *multilayer perceptron*) é uma Rede Neural Artificial - uma estrutura inspirada pelo sistema nervoso dos organismos superiores. O aprendizado supervisionado leva em conta dados de entrada e resultados já conhecidos para treinar e validar um sistema que, em seguida, pode ser utilizado na predição de novas saídas com novos dados de entrada. O *Perceptron* pode conter diversas camadas (*layers*) para trabalhar os valores de entrada até resultar em um valor final.

De acordo com Silva, Flauzino e Spatti (2010), na operação convencional do *Perceptron* Múltiplas Camadas, não ocorre a realimentação de dados com valores gerados nas camadas escondidas ou pela camada de saída. Nesse modelo, a propagação de sinais segue um único sentido, dos neurônios de entrada até os neurônios de saída. Um dos algoritmos de aprendizado mais utilizado é chamado de *Backpropagation*, ou Algoritmo de Retropropagação do Erro. É por meio de algoritmos como esse que os pesos em cada camada são atualizados com o propósito de reduzir o erro na resposta da rede.

A MLP utiliza os dados fornecidos inicialmente, separando-os em conjunto de aprendizado, conjunto de validação e conjunto de teste. Ao final do treinamento, o mesmo utiliza este último para checar se o modelo possui boa assertividade nas predições. Por fim, o modelo treinado e validado pode ser utilizado para prever novos valores apenas com base nas variáveis de entrada.

O *Perceptron* Múltiplas Camadas para aplicações de regressão é disponibilizado

pela Biblioteca *Scikit-Learn* como uma forma facilitada de se implementar modelos de Redes Neurais Artificiais (RNA). O modelo disponibilizado pela biblioteca possibilita a customização do número de camadas, a quantidade de neurônios, tal como a função de ativação e o modelo de otimização de pesos, dentre outros parâmetros. Um ativador amplamente utilizado é o sigmoide, expresso por:

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

2.3.6 Aprendizado Profundo

A biblioteca *Keras* da Plataforma de Código Aberto para Aprendizado de Máquina, *Tensorflow*, é amplamente empregada na criação de Redes Neurais Artificiais (MARTIN ABADI *et al.*, 2015). Como apresentado em Geron (2019), esse pacote possibilita uma customização muito mais abrangente que o modelo MLP disponibilizado pela Biblioteca *Scikit-Learn* em Python. As possibilidades se expandem, mas não se limitam à técnicas de normalização mais avançadas, inicializações e funções de ativação personalizadas, camadas para "adormecer" neurônios, reutilizar camadas iniciais de outros modelos, criar laços de repetição, gerar resultados auxiliares, entre outras. Embora o funcionamento se assemelhe ao exposto anteriormente, o *Tensorflow* disponibiliza uma ferramenta mais versátil para criação de modelos mais específicos.

2.3.7 Normalização de Intervalos

Feature scaling, ou normalização de intervalos, é uma técnica utilizada para tratar dados que possuam grande variação de valores, com objetivo de padronizar os dados em limites fixos para que o algoritmo de Aprendizado de Máquina tenha maior facilidade na interpretação desses e não penalizem uma variável por ter uma menor amplitude que as demais. Para esse, a biblioteca responsável por escalar os dados se chama *StandardScaler* e é disponibilizada como um pré-processamento por Pedregosa *et al.* (2011), sendo definido pela Equação 3, onde x e \bar{x} são o valor e sua média, respectivamente, e σ é o desvio padrão.

$$z - score = \frac{x - \bar{x}}{\sigma} \quad (3)$$

Além disso, a normalização dos dados de entrada pode auxiliar na obtenção de melhores resultados, com menores erros, e em um menor tempo necessário para treinamento (SOLA; SEVILLA, 1997). As entradas podem ser restritas a um valor entre 0 e 1 ou de -1 a 1.

2.3.8 Métrica R-Quadrado

A Métrica R-quadrado (R^2) é uma medida estatística que aponta o ajuste entre a regressão e os dados fornecidos. Tal parâmetro é empregado para aferição de modelos de Aprendizado de Máquina e é um atributo integrado a diversos modelos. O valor de R^2 varia de 0 e 1, sendo que o valor máximo significa que o modelo consegue explicar toda variabilidade dos dados em função da média.

A Biblioteca *Scikit-Learn*, disponibiliza o cálculo de R-quadrado pela Equação (4), sendo y_i o valor verdadeiro de uma variável, \hat{y}_i sendo a variável prevista e \bar{y} a média de todas as variáveis reais (**scikitlearn**):

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

2.3.9 Análise de Normalidade da Amostra

O teste de normalidade é realizado com o propósito de identificar se uma amostra vem de uma distribuição normal. Em D'Agostino (1971) um modelo é apresentado, e este, posteriormente, é implementado em uma biblioteca de Python. A biblioteca SciPy (VIRTANEN *et al.*, 2020) apresenta o modelo como *normaltest* e permite a realização de testes de hipótese.

Em testes de normalidade, uma Hipótese Nula é definida e um nível de significância é escolhido. Se o valor-p, resultado do teste, for inferior ao nível de significância, a Hipótese Nula pode ser rejeitada.

3 METODOLOGIA

Com base na literatura, três características geométricas de aletas planas foram escolhidas para serem estudadas mais profundamente, visando avaliar a influência de suas variações no desempenho térmico de dissipadores de calor aletados aplicados no resfriamento de componentes eletroeletrônicos. Essas características e suas influências foram estudadas fazendo uso de diferentes modelos de *Machine Learning*. Os parâmetros geométricos avaliados foram: altura, espessura e número total de aletas.

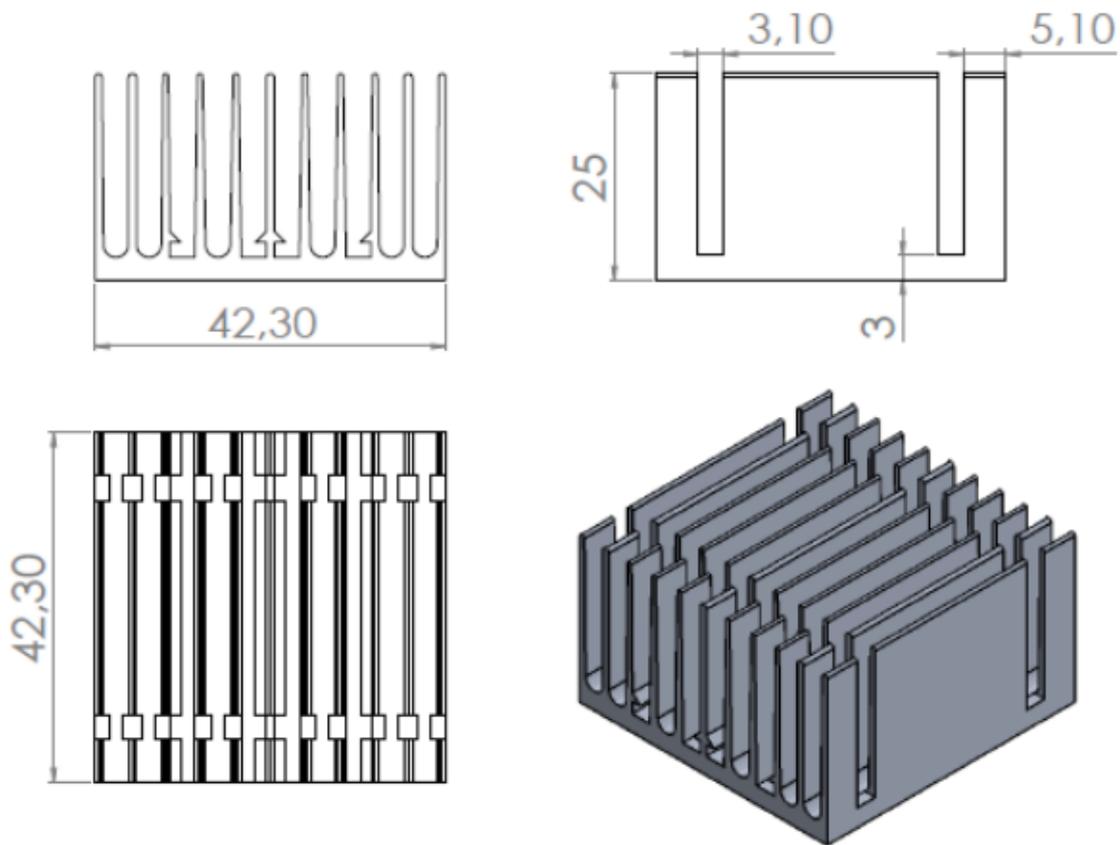
O dissipador de calor aletado utilizado como padrão no presente estudo de otimização geométrica é apresentado na Figura 2. Esse trocador de calor de aletas planas é idêntico ao utilizado no trabalho de Maschietto (2018). Essa peça-base, feita de alumínio, pode ser modelada como uma base quadrada com 42,3 mm de lado, com 11 aletas de 25 mm de altura e espessura igual a 1 mm cada e possuindo dois rasgos de 3,1 mm. Além disso, para o escoamento de ar sobre o dissipador de calor aletado foi utilizado um ventilador axial **Panasonic**TM, modelo ASFN 82371, com dimensões conforme a Figura 3. Na Figura 4, é mostrada a seção de testes do aparato experimental desenvolvido por Maschietto (2018) para obtenção dos resultados experimentais.

Para entender o impacto da variação dos parâmetros geométricos no desempenho térmico do dissipador de calor aletado, as combinações de três características foram especificadas e, posteriormente, desenhadas em 3D. A partir de dados experimentais obtidos em Maschietto (2018), o resfriamento por convecção forçada de ar desse dissipador de calor aletado foi simulado numericamente por meio do programa comercial Ansys/Fluent visando a comparação dos resultados computacionais com os resultados experimentais, buscando assim a validação do modelo de simulação numérica.

Uma vez validado o modelo de simulação numérica, o próximo passo foi a criação do plano de testes por meio do método de Planejamento de Experimentos, onde as características variadas e a quantidade de combinações foram consideradas para montar o conjunto de experimentos. Os cenários resultantes de todas as combinações de níveis foram então simulados numericamente por meio do programa Ansys/Fluent visando a obtenção do banco de dados.

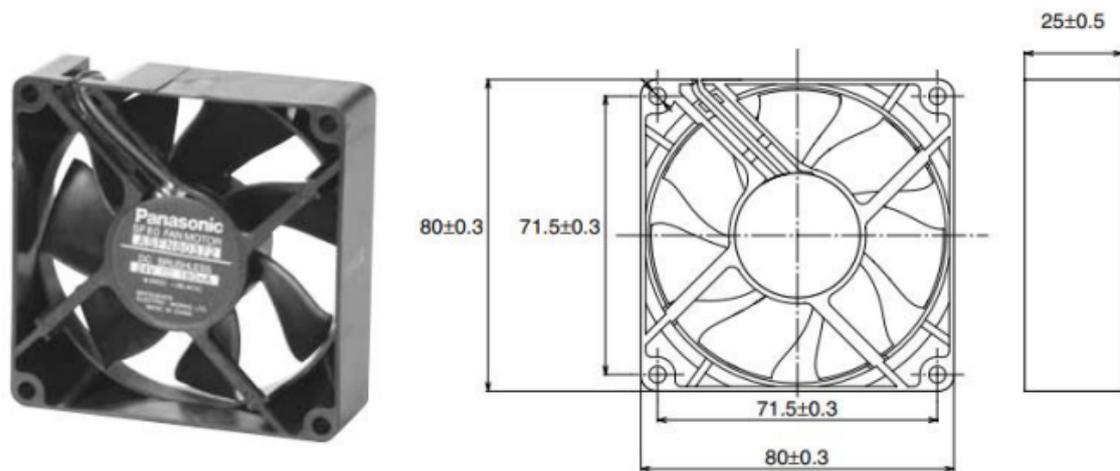
Com os resultados das simulações numéricas, os dados foram inseridos em um código em linguagem de programação Python, em formato de *Dataframe*, e utilizados

Figura 2 – Desenho técnico do dissipador de calor usado na validação, medidas em [mm]



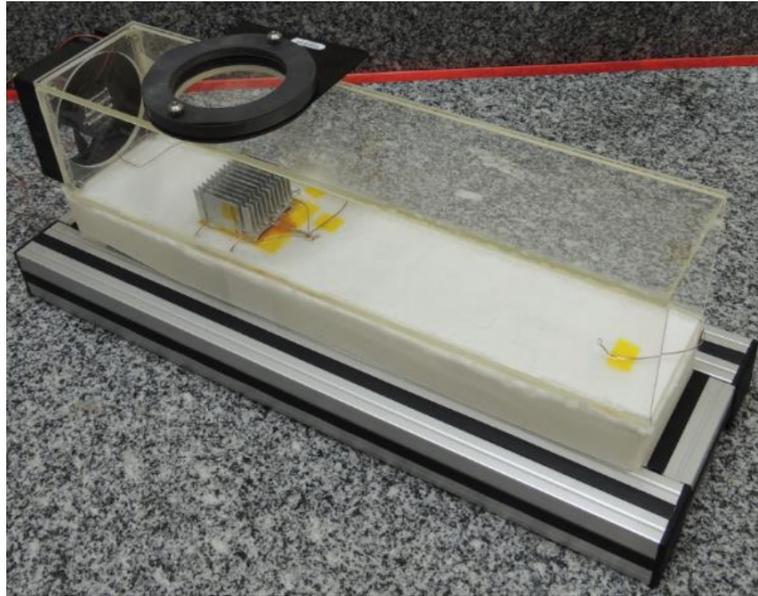
Fonte: Maschietto (2018).

Figura 3 – Desenho técnico do dissipador de calor usado na validação, medidas em [mm]



Fonte: Maschietto (2018).

Figura 4 – Seção de testes do aparato experimental utilizado em Maschietto (2018)



Fonte: Maschietto (2018).

para treinar modelos de Aprendizado de Máquina. Por fim, os resultados e as conclusões obtidas por meio da análise dos dados foram dispostos de forma gráfica para facilitar a interpretação e a comparação de grandezas.

Para possibilitar o desenvolvimento do projeto, diversas ferramentas foram empregadas. Após a obtenção dos resultados numéricos, os dados provenientes das simulações numéricas foram transferidos para um programa de planilhas. Em sequência à coleta de dados, o processo de limpeza, treinamento do modelo, análise de dados e teste de hipóteses foi feito na linguagem de programação Python, para tal, o programa Visual Code Studio foi empregado com o propósito de facilitar escrita, compilação e identificação de erros.

3.1 CRIAÇÃO DO DOE

Tomando as medidas básicas da peça-padrão do dissipador de calor aletado como modelo, as novas peças combinaram as características monitoradas para testar a influência de cada uma na composição do resultado final do desempenho térmico. Três variáveis foram combinadas: altura das aletas, espessura das aletas e o número total de aletas planas. As combinações destas variáveis podem ser vistas na Tabela 1.

Tabela 1 – Configurações do DOE

Caso Base	Altura	Espessura	Núm. Aletas
1	-	-	-
2	-	-	0
3	-	-	+
4	-	0	-
5	-	0	0
6	-	0	+
7	-	+	-
8	-	+	0
9	-	+	+
10	+	-	-
11	+	-	0
12	+	-	+
13	+	0	-
14	+	0	0
15	+	0	+
16	+	+	-
17	+	+	0
18	+	+	+

Fonte: autoria própria.

Como pode ser observado, a altura da aleta variou entre dois extremos, a espessura entre três valores e a quantidade de aletas também possuiu três variações. As variações de cada parâmetro em valores absolutos são:

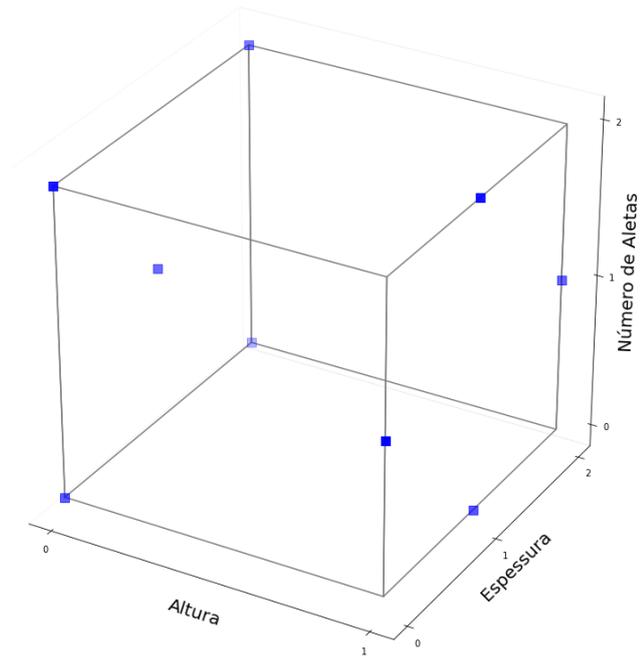
- Altura da aleta: 25 mm (-) e 35 mm (+);
- Espessura da aleta: 1 mm (-), 2 mm (0) e 3 mm (+);
- Número de aletas: 11 (-), 8 (0) e 5 (+).

Contudo, devido ao alto custo computacional, uma técnica conhecida como *Generalized Subset Design* (GSD) foi empregada para reduzir pela metade o número de combinações necessárias. A seleção pode ser feita por meio da biblioteca PyDOE2 da linguagem Python ou por um desenvolvimento geométrico, conforme a Figura 5.

3.2 MODELAGEM CFD

A modelagem numérica do problema de resfriamento de componentes eletroeletrônicos em questão foi realizada utilizando o programa comercial de CFD Ansys/Fluent, em sua versão 2021 R1. As equações governantes concomitantemente com as condições de contorno apropriadas foram resolvidas pelo Método dos Volumes Finitos (PATANKAR, 1980). As simulações numéricas foram executadas no Laboratório de

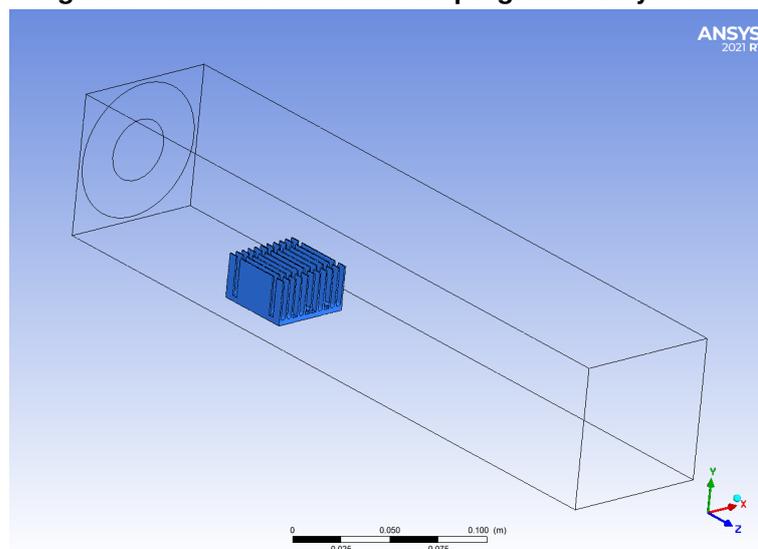
Figura 5 – Seleção das combinações a serem simuladas por abordagem geométrica



Fonte: autoria própria.

Pesquisa Computacional (LPC) vinculado ao Departamento Acadêmico de Mecânica (DAMEC) da Universidade Tecnológica Federal do Paraná (UTFPR), *Campus* Ponta Grossa. Na Figura 6, é apresentado o modelo construído no programa de CFD visando a obtenção dos resultados numéricos utilizados na validação do modelo.

Figura 6 – Modelo construído no programa Ansys/Fluent



Fonte: autoria própria.

A técnica de resolução numérica utilizada envolveu a configuração de certas

especificações no programa de CFD. Foi utilizado o *solver Pressure-based Coupled Solver*, habilitado usando o tratamento do acoplamento pressão-velocidade Acoplado. Em relação à discretização dos gradientes, foi utilizado o método *Least Squares Cell Based*, padrão do programa computacional comercial. A discretização dos termos difusivo-convectivos foi realizada com a utilização do Esquema *Upwind* de Segunda Ordem. O modelo de turbulência escolhido foi o RNG $k-\epsilon$, utilizando as constantes da equação conforme as simulações numéricas executadas por Maschietto (2018). Os critérios de convergência escolhidos para as simulações numéricas foram de 10^{-4} para a continuidade e 10^{-7} para as equações de *momentum* e de energia.

3.3 GERAÇÃO DO BANCO DE DADOS

Após a validação do modelo numérico, a próxima etapa consistiu na obtenção dos resultados numéricos por meio das simulações numéricas no programa Ansys/Fluent visando a geração do banco de dados para posterior aplicação dos diferentes modelos de Aprendizado de Máquina. Para tal, foram considerando diferentes cenários de configurações geométricas dos dissipadores de calor aletados, definidos pelo método de DOE e reduzidos, devido ao alto custo computacional, pela técnica *Generalized Subset Design* (GSD). As características geométricas dos cenários selecionados estão apresentadas na Tabela 2.

Tabela 2 – Combinações de geometria dos cenários DOE/GSD para geração do banco de dados

Item (Caso base)	Altura (mm)	Espessura (mm)	Núm. Aletas
A (1)	25	1	11
B (3)	25	2	5
C (5)	25	2	8
D (7)	25	3	11
E (9)	25	3	5
F (11)	35	1	8
G (13)	35	2	11
H (15)	35	2	5
I (17)	35	3	8

Fonte: autoria própria.

3.4 TREINAMENTO DE MODELOS PREDITIVOS

Com os resultados das simulações numéricas obtidos a partir dos cenários da Tabela 2 e conseqüente geração do banco de dados, os valores encontrados foram então armazenados em formato de arquivo de valores separados por vírgulas (*.csv) para alimentar e treinar os algoritmos de Aprendizado de Máquina.

Como mencionado anteriormente, o processo de treinamento dos modelos preditivos pode ser dividido em cinco etapas: importação de dados, limpeza de dados, *feature scaling* (padronização dos recursos), criação dos conjuntos de treinamento e validação, e avaliação de precisão.

Os valores estabelecidos na Tabela 2 foram empregados como dados de teste, mas o teste deve ser feito com dados diferentes, não utilizados no processo de treinamento. Dessa forma, os Casos #2, #6 e #16, de agora em diante nomeados de casos J, K e L, respectivamente, que apesar de serem excluídos do DOE/GSD, foram utilizados para testar os modelos de Aprendizado de Máquina. Esses três cenários estão apresentados na Tabela 3.

Tabela 3 – Combinações de geometria dos cenários para validação e testes dos algoritmos de Aprendizado de Máquina

Caso (Caso Base)	Altura [mm]	Espessura [mm]	Núm. Aletas
J (2)	25	1	8
K (6)	25	2	5
L (16)	35	3	11

Fonte: autoria própria.

Nesse trabalho, os diferentes modelos de Aprendizado de Máquina, avaliados por meio da utilização da Biblioteca *Scikit-Learn* (PEDREGOSA *et al.*, 2011) em linguagem de programação Python, foram:

- *Decision Tree Regressor* (Regressão de Árvore de Decisões).
- *Random Forest Regressor* (Regressão de Floresta Aleatória).
- *Linear Regressor* (Regressão Linear).
- *MLP Regressor* (Regressão por *Perceptron* Múltiplas Camadas).
- *Support Vector Regression* (Regressão de Vetores Suporte).

Além desses diferentes modelos de Aprendizado de Máquina, a Biblioteca "Keras" da Plataforma *Tensorflow* (MARTIN ABADI *et al.*, 2015) foi empregada para construir e testar Redes Neurais.

Todos modelos de Aprendizado de Máquina da Biblioteca *Scikit-Learn* foram treinados utilizando os dados da Tabela 2 sempre como entrada, mas apresentando três possíveis saídas diferentes: temperatura máxima atingida pelo dissipador de calor aletado, número de Nusselt e resistência térmica. Cada modelo deve ser criado especificamente para prever esses resultados individualmente e, após a verificação de precisão com o grupo de teste da Tabela 3, os modelos que tiverem um melhor desempenho para cada saída foram selecionados. Para elencar os melhores preditores, a Métrica R-quadrado (R^2) foi calculada para todos os modelos treinados e os resultados foram elencados em tabelas para fins de comparação.

4 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados numéricos para o resfriamento de diferentes configurações de dissipadores de calor aletados utilizando o programa de CFD, os resultados do estudo estatístico de Planejamento de Experimentos (DOE) e os resultados da aplicação dos diferentes modelos de Aprendizado de Máquina nos diferentes cenários analisados.

Conforme mencionado anteriormente, devido ao alto custo computacional, a Técnica *Generalized Subset Design* (GSD) foi empregada para reduzir o número de combinações necessárias ao DOE. Apenas nove cenários foram necessários para geração do banco de dados que foi utilizado no treinamento dos Métodos de Aprendizado de Máquina. Adicionados à esses, outros três cenários foram utilizados para avaliar o desempenho dos métodos treinados. Na Figura 7, são ilustrados os modelos 3D de cada um dos dissipadores de calor aletados utilizados nos doze cenários para geração do banco de dados.

4.1 SIMULAÇÕES NUMÉRICAS

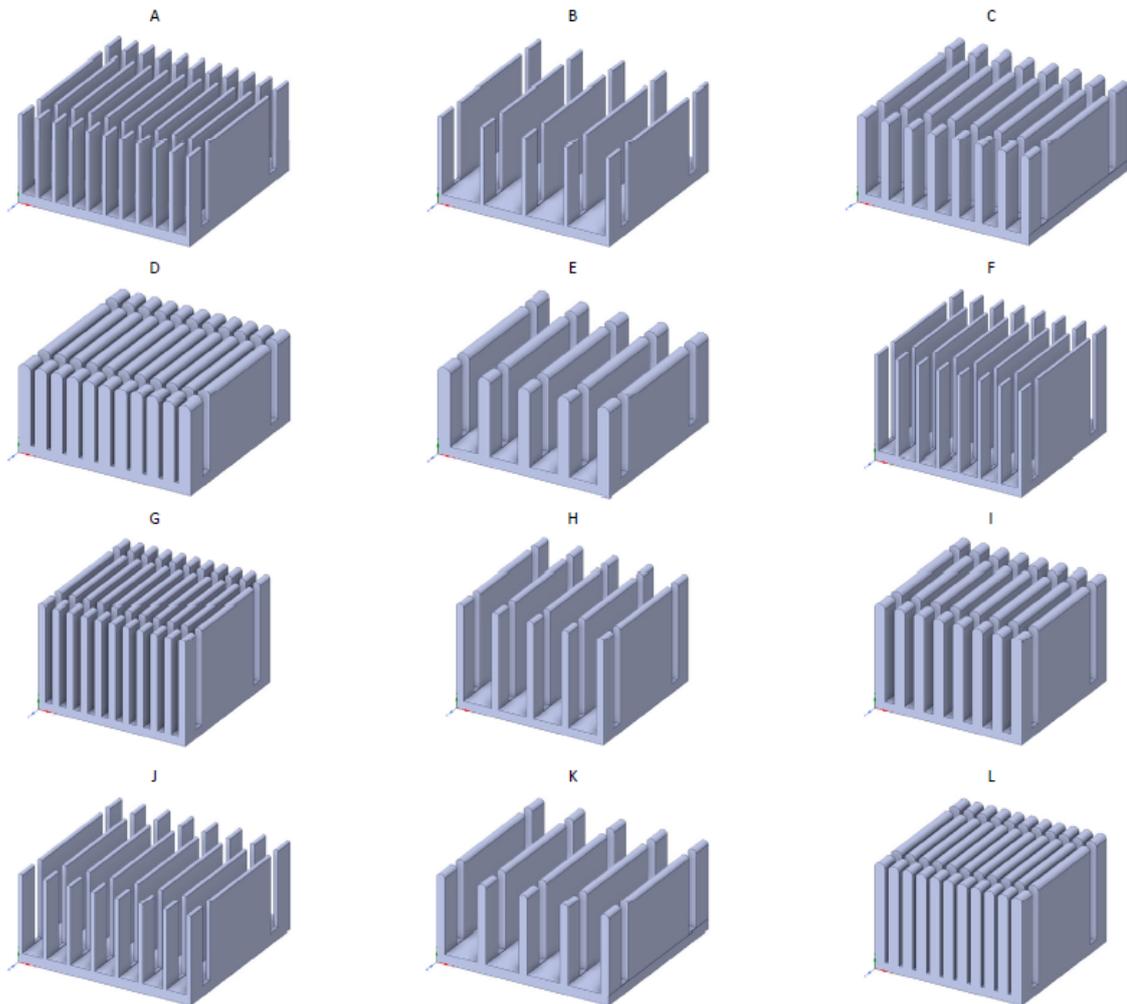
Para que os resultados apresentados sejam considerados confiáveis, dispõe-se primeiramente os resultados e comparações obtidos durante o processo de validação. Em seguida, resultados preliminares das simulações são expostos, avaliando alguns dos cenários cujos dados serão alimentados no treinamento dos algoritmos de Aprendizado de Máquina.

4.1.1 Validação da Modelagem CFD

Como mencionado anteriormente, a validação da modelagem CFD foi executada com base no trabalho de Maschietto (2018). O modelo construído no programa de CFD foi apresentado na Figura 6.

Primeiramente, foi realizado um estudo de refinamento de grade computacional visando garantir resultados numéricos independentes da grade computacional utilizada. Nesse estudo, dez malhas computacionais foram construídas utilizando parâmetros de localização de camada de inflação, método de criação de malha e características

Figura 7 – Modelo 3D dos dissipadores de calor utilizados na geração do banco de dados



Fonte: autoria própria.

de ajuste idênticas, alterando apenas o valor de tamanho de elemento do corpo. O objetivo foi a seleção dos valores e parâmetros que seriam empregada no domínio de cálculo para obtenção dos resultados de simulação numérica e geração do banco de dados. Na obtenção das grades computacionais um recurso de adaptação de grade computacional disponível no programa de CFD foi utilizado para refiná-las em regiões críticas do escoamento. O número de elementos no domínio de cálculo foi aumentado através da redução do valor de tamanho de elemento do corpo do dissipador e do ar, até que refinamentos adicionais de grade computacional alteravam pouco, dentro de critérios estabelecidos, os resultados numéricos.

As simulações numéricas do estudo de refinamento foram executadas considerando $Re = 10063$. Os resultados numéricos obtidos para a temperatura média do dissipador de calor aletado em função do número de elementos na grade computacional

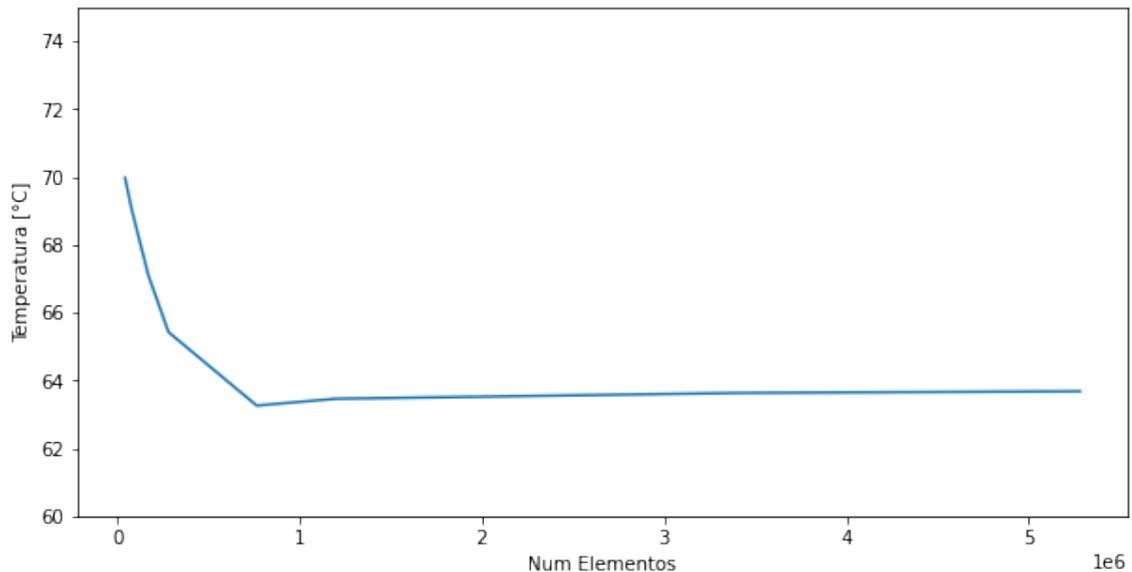
são apresentados na Tabela 4 e na Figura 8. Como pode ser observado, a partir de 764.000 elementos na grade computacional, a diferença entre os resultados de duas grades computacional consecutivas foi de até 1,2%.

Tabela 4 – Dados da análise de refinamento de malha

Número de Elementos	Ts [°C]	ΔT para a próxima malha
43.261	70,60	-
46.218	69,97	-0,89%
78.784	68,50	-2,10%
169.986	66,24	-3,30%
281.226	66,26	-0,03%
764.841	63,10	-4,77%
1.195.272	63,50	0,63%
2.119.745	62,86	-1,01%
3.399.723	63,63	1,22%
5.281.132	63,68	0,08%

Fonte: autoria própria.

Figura 8 – Análise de refinamento de malha

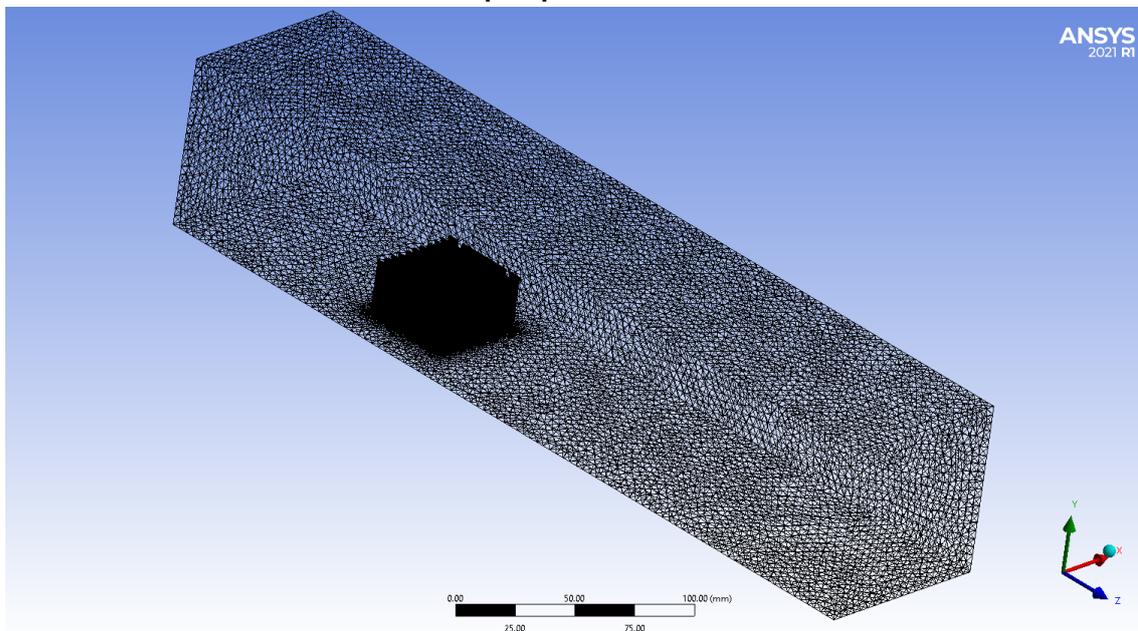


Fonte: autoria própria.

Dessa forma, a grade computacional que foi escolhida para obtenção das simulações numéricas considerado o problema de resfriamento de um dissipador de calor aletado foi a Grade Computacional 3D não-uniforme no domínio de solução contendo 2.119.745 elementos. Essa escolha foi feita considerando que a malha se posiciona dentro da região de estabilidade de resultados, mas com uma margem segura para redução de até 64% do número de elementos, de forma que, na modelagem dos doze cenários escolhidos, a malha ainda estaria dentro da região de estabilidade.

A malha escolhida é mostrada em uma perspectiva 3D na Figura 9 ou em detalhes em uma seção transversal do dissipador de calor aletado na Figura 10. Essa grade computacional foi mais concentrada nas regiões próximas às interface sólido-fluido devido aos maiores gradientes das variáveis primitivas existentes. O tempo de simulação computacional foi em torno de 35 minutos em um sistema com processador de seis núcleos, frequência de 2.80 GHz e 9 MB de cache, duas unidades de memória RAM de 8 GB e frequência de 2666 MHz, instalado em uma unidade de estado sólido (SSD - *solid-state drive*) com velocidade de leitura e gravação de 500 MB/s e 350 MB/s respectivamente.

Figura 9 – Grade computacional 3D não-uniforme utilizada nas simulações numéricas - perspectiva 3D

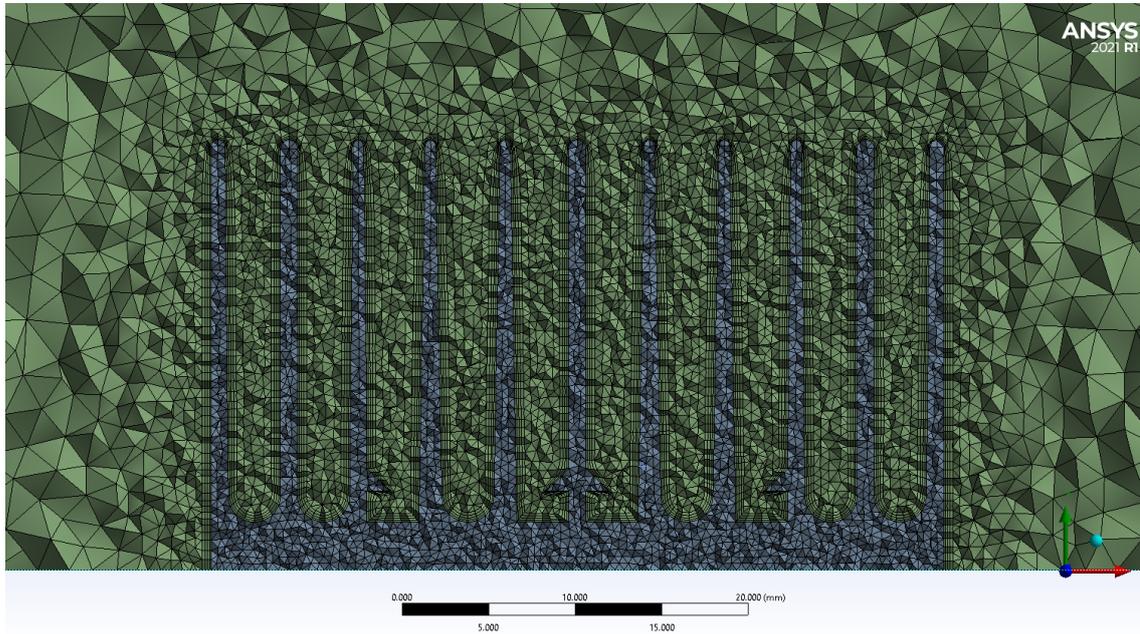


Fonte: autoria própria.

Após a obtenção da grade computacional, foram executadas simulações numéricas considerando cenários de resfriamento do trocador de calor aletado dissipando uma potência de 25W para escoamentos com números de Reynolds de 7415, 10063, 15360 e 23305. A Figura 12 apresenta os resultados numéricos encontrados para a distribuição de temperatura no dissipador de calor aletado para os cenários estudados. Os resultados numéricos encontrados para o número de Nusselt e temperatura atingida foram comparados com os resultados numéricos e experimentais de Maschietto (2018).

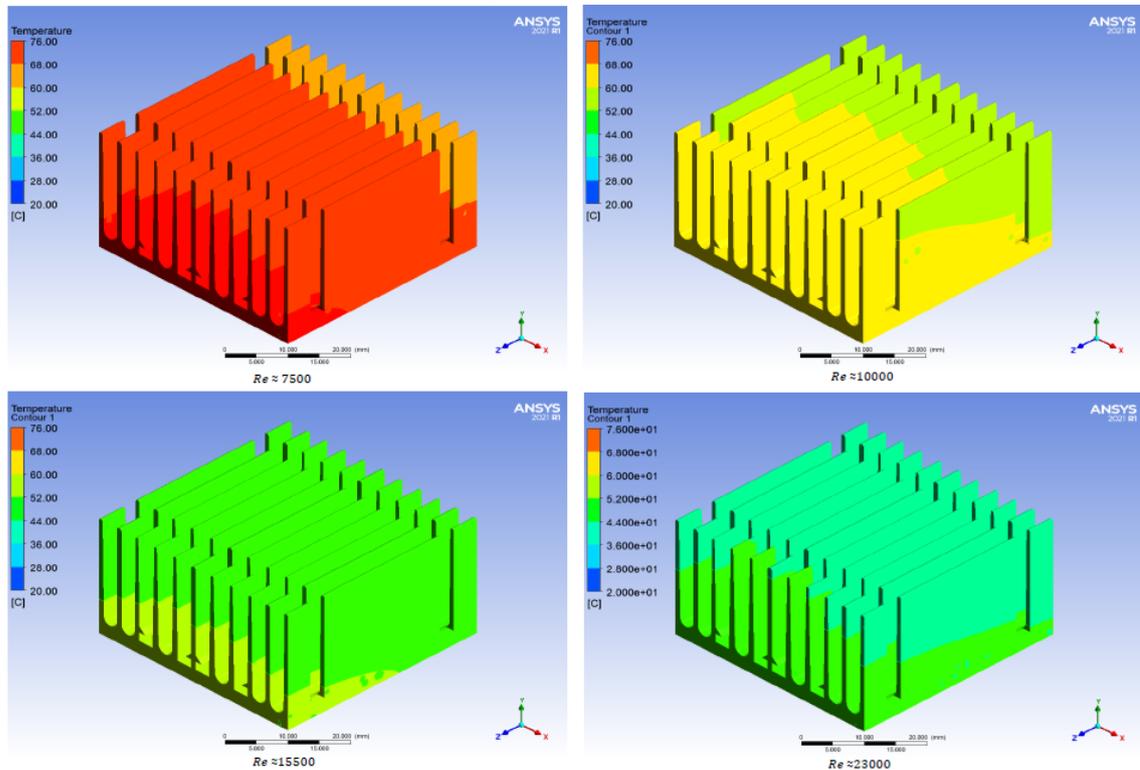
A comparação dos resultados para as temperaturas máximas atingidas no dissipador de calor aletados considerando os diferentes cenários é apresentada na Figura

Figura 10 – Detalhe da grade computacional em uma seção transversal próxima ao dissipador de calor aletado



Fonte: autoria própria.

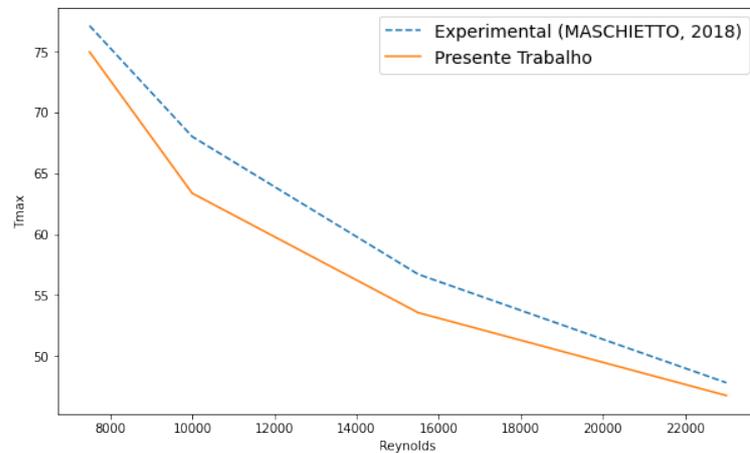
Figura 11 – Distribuição de temperaturas no dissipador de calor aletado considerando diferentes condições de escoamento



Fonte: autoria própria.

12 e na Tabela 5. Nota-se que as temperaturas máximas obtidas de forma empírica em Maschietto (2018) apresentam um desvio entre 2,25% e 7,34% para os valores encontrados nesse trabalho por simulação numérica utilizando o programa de CFD. Ressalta-se que os dados experimentais apresentados em Maschietto (2018) para as temperaturas máximas possuem uma faixa de incerteza experimental de 1,27°C. Quando comparado aos resultados das simulações numéricas apresentados em Maschietto (2018), o desvio máximo encontrado para a temperatura do dissipador de calor aletado foi de 7,8%, com maior desvio médio de 5,3%.

Figura 12 – Comparação da temperatura máxima dos dissipadores de calor aletados em função do número de Reynolds



Fonte: autoria própria.

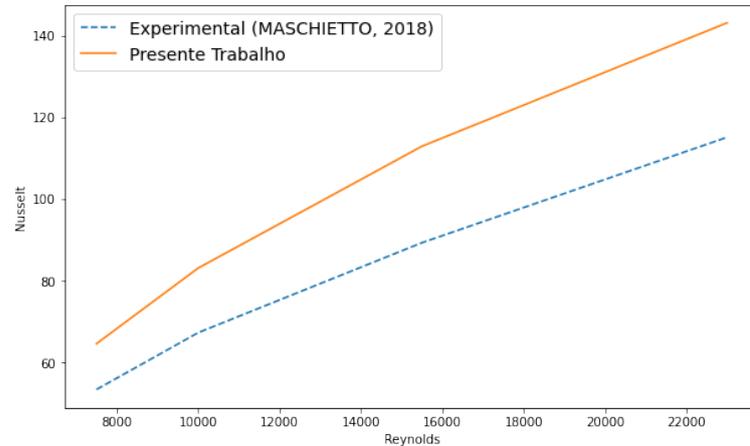
Tabela 5 – Comparações de temperaturas máximas entre as simulações numéricas e os dados experimentais de Maschietto (2018)

Re	T_{exp} [°C]	T_{num} [°C]	Desvio [%]
7500	77,1	75,0	-2,87
10000	68,0	63,4	-7,34
15500	56,7	53,6	-5,88
23000	47,8	46,8	-2,25

Fonte: autoria própria.

A comparação entre os resultados encontrados nas simulações numéricas e os experimentais para o número de Nusselt são apresentados na Figura 13 e na Tabela 6. Como pode ser observado, a diferença entre esses resultados variou de 17,3% até 20,9%. A comparação entre os presentes resultados numéricos e os resultados das simulações numéricas de Maschietto (2018) apresentou um desvio entre 2,9% e 17% para os diferentes cenários estudados.

Figura 13 – Comparação do número de Nusselt em função do número de Reynolds



Fonte: autoria própria.

Tabela 6 – Comparações do número de Nusselt entre as simulações numéricas e os dados experimentais de Maschietto (2018)

Re	Nu_{exp}	Nu_{num}	Desvio [%]
7500	53,4	64,6	17,3
10000	67,3	83,1	19,0
15500	89,3	112,9	20,9
23000	115,1	143,1	19,6

Fonte: autoria própria.

Ressalta-se que Güreşçi *et al.* (2018) e Kumar e Bartaria (2013) encontraram em seus estudos numérico-experimentais uma variação do número de Nusselt de 19,9% e ao redor de 25% entre os resultados obtidos numérica e experimentalmente, respectivamente. Esses valores foram considerados aceitáveis para validação da modelagem CFD de simulação numérica dada a natureza do coeficiente de transferência de calor por convecção forçada.

4.1.2 Simulação Numérica dos Cenários para Geração do Banco de Dados

Para geração do banco de dados, foram executadas simulações numéricas utilizando o programa de CFD considerando o resfriamento de diferentes configurações de dissipadores de calor aletados. Para tal, foram simulados numericamente os nove cenários (Casos A a I) apresentados na Tabela 2 e os três cenários (Casos J, K e L) mostrados na Tabela 3. Os parâmetros térmicos de interesse encontrados foram: temperatura máxima da superfície do dissipador de calor aletado, número de Nusselt e resistência térmica do dissipador de calor aletado.

Na Figura 14 são apresentados os perfis de velocidade do escoamento de ar sobre o dissipador de calor aletado no plano yz para os Casos A, E e G. Pode ser observado o comportamento do escoamento de ar nesse sistema, como a entrada possui em formato anular com dimensões idênticas às do ventilador axial utilizado na investigação experimental de Maschietto (2018), há uma zona de recirculação imediatamente após na entrada de ar. Além disso, o escoamento através do dissipador de calor aletado causa uma diminuição de velocidade e uma queda de pressão, indicada pela recirculação a jusante do trocador de calor de aletas planas.

Na Figura 15 são apresentados os mapas de isotérmicas no plano yz para os problemas de transferência de calor dos Casos A, E e G. A influência das características fluidodinâmicas do escoamento sobre o dissipador de calor aletado na distribuição de temperaturas pode ser notada através da esteira térmica gerada à jusante do dissipador de calor.

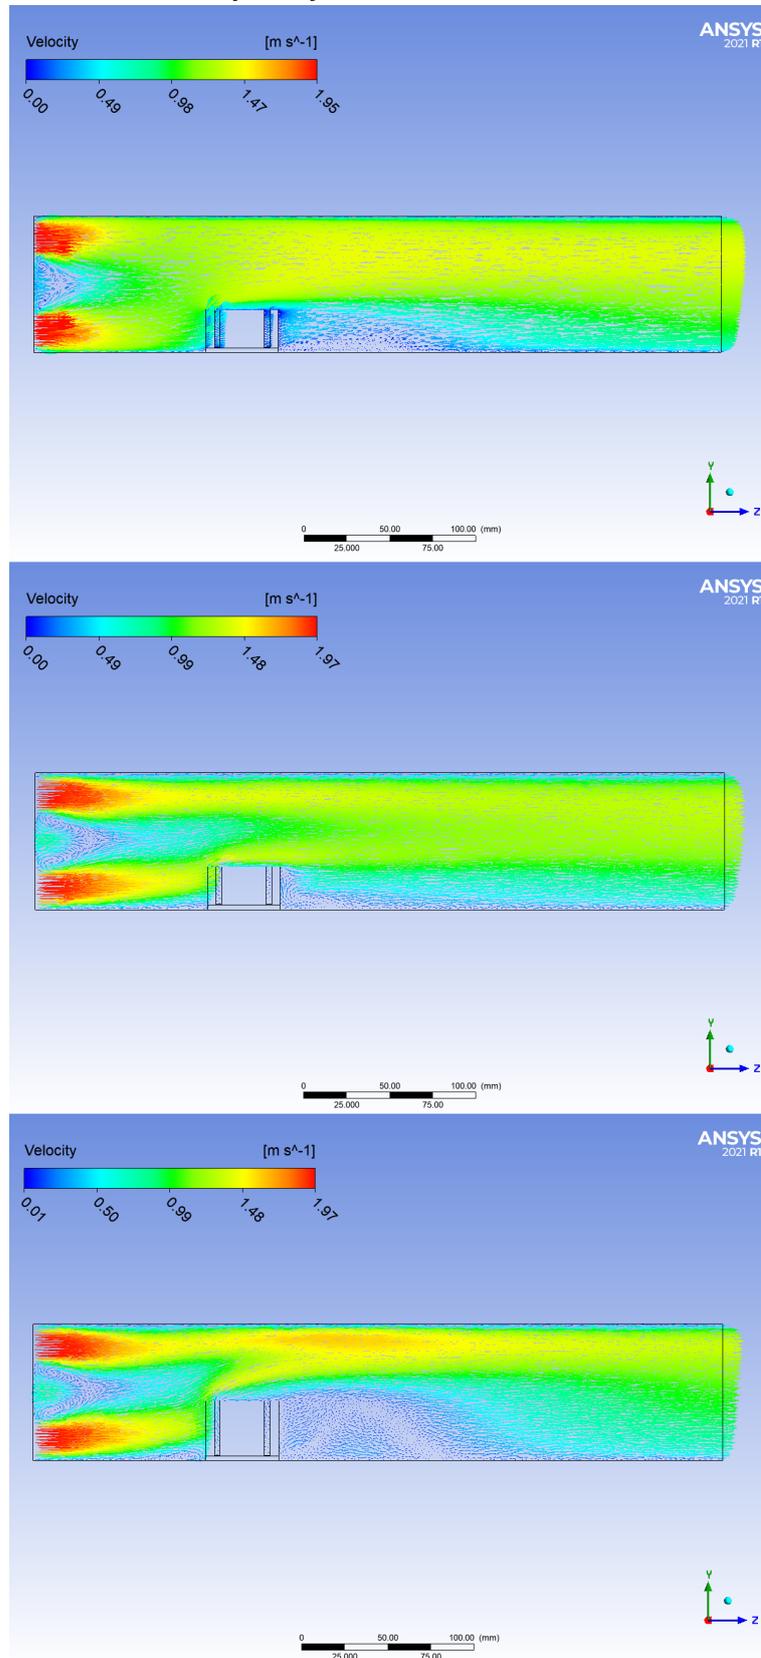
Do comportamento termofluidodinâmico dos cenários simulados, podem ser notados os efeitos de altura e espaçamento das aletas planas do dissipador de calor no escoamento de ar e na transferência de calor por convecção forçada. Aletas mais altas e agrupadas como as do Caso G causam uma grande perturbação no escoamento do ar intensificando a transferência de calor convectiva, enquanto aletas mais distantes e mais baixas, como no Caso E, pouco perturbam o escoamento de ar diminuindo a troca térmica entre o dissipador de calor aletado e o fluido de resfriamento.

Os resultados obtidos para a temperatura máxima, número de Nusselt e resistência térmica, por meio das simulações numéricas utilizando programa de CFD, para os diferentes cenários de resfriamento de um dissipador de calor aletado estudados, são apresentados na Tabela 7. Como mencionado na Seção 3.3, esses resultados numéricos são os que foram utilizados para a geração do banco de dados visando o estudo de otimização geométrica do dissipador de calor de aletas planas de forma estatística e pelo emprego de Aprendizado de Máquina.

4.2 ANÁLISE PELO MÉTODO DE PLANEJAMENTO DE EXPERIMENTOS

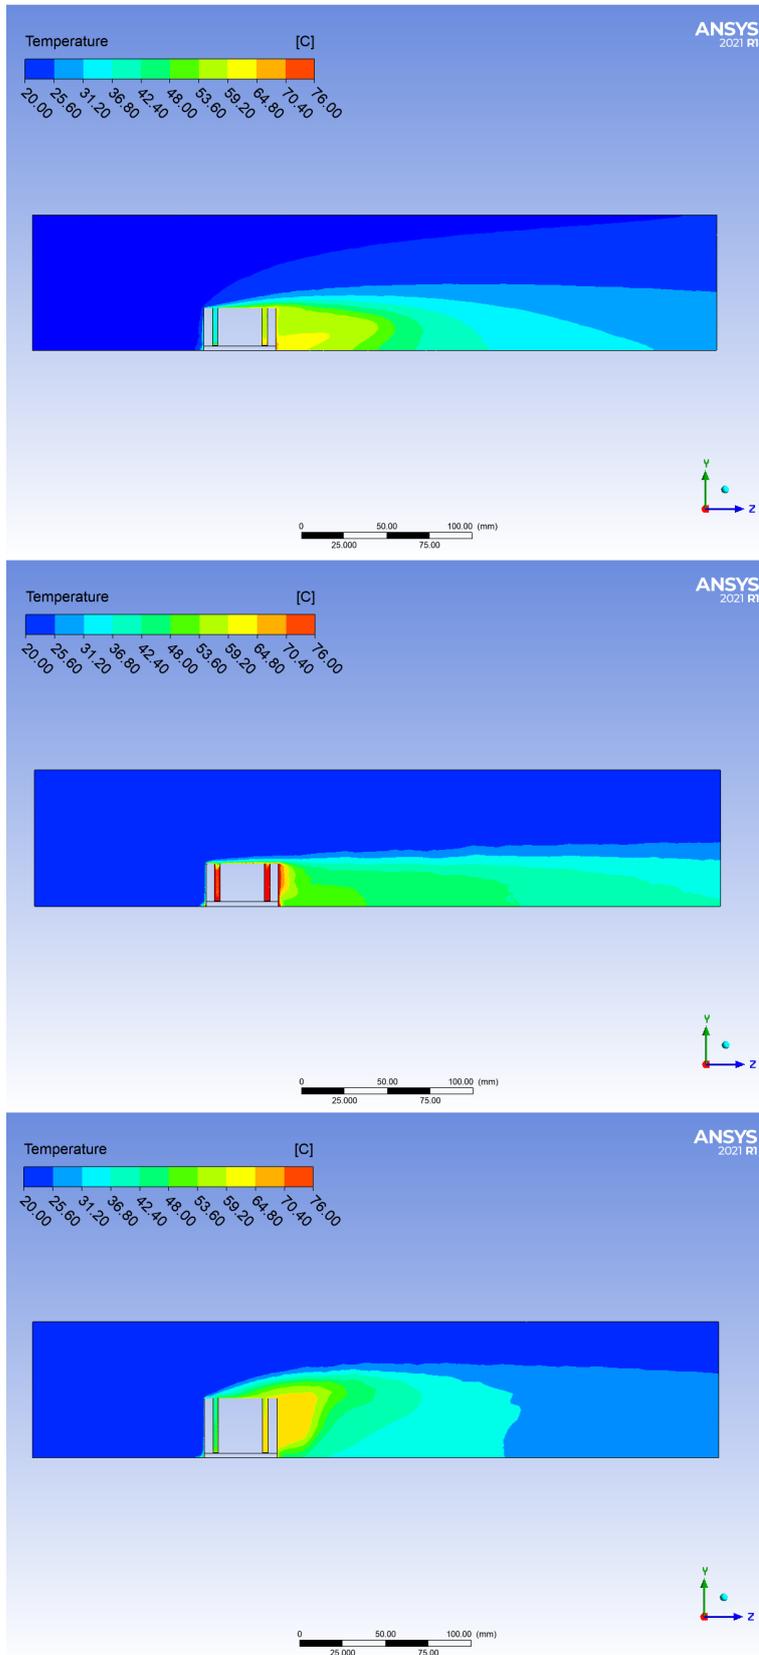
Conforme a etapa de planejamento da geração de banco de dados, alguns cenários foram selecionados na biblioteca PyDOE2 da linguagem de programação Python como representativos do sistema de resfriamento analisado. Utilizando os

Figura 14 – Perfis de velocidade do escoamento de ar sobre o dissipador de calor aletado no plano yz - Casos A, E e G



Fonte: autoria própria.

Figura 15 – Contorno de temperatura do ar - Casos A, E e G



Fonte: autoria própria.

Tabela 7 – Valores encontrados para os índices de desempenho dos casos

Caso	T_{max} [°C]	Nu	R_t [°C/W]
A	67,7	78,6	1,64
B	126,9	102,0	2,60
C	72,7	91,6	1,98
D	162,9	31,1	4,16
E	94,9	89,0	2,87
F	61,2	96,9	1,42
G	63,0	61,8	1,56
H	77,4	93,3	2,10
I	63,3	76,9	1,59
J	76,3	98,3	1,95
K	98,8	89,6	2,99
L	94,7	31,5	2,90

Fonte: autoria própria.

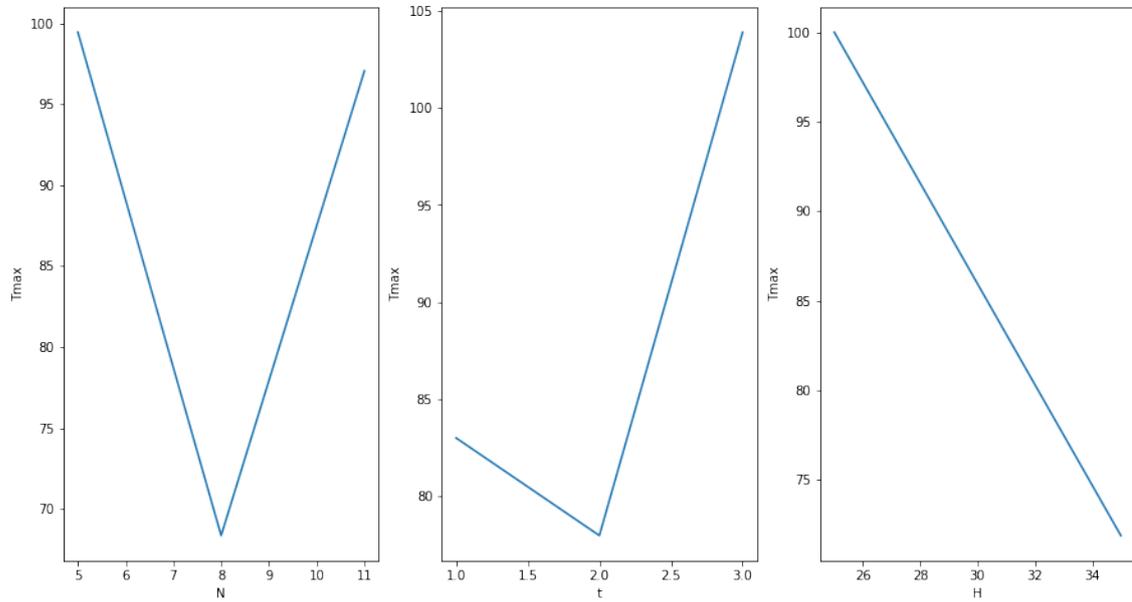
dados obtidos com as simulações numéricas em programa comercial CFD para os cenários analisados, foi constatado os efeitos que as alterações de variáveis geométricas causaram na temperatura máxima atingida no dissipador de calor aletado, no número de Nusselt e na resistência térmica do dispositivo por meio do emprego do método de DOE. Para facilitar a visualização desse impacto são apresentados gráficos.

Na Figura 16, é mostrado o impacto da variação das configurações geométricas das aletas planas do dissipador de calor na temperatura máxima atingida pelo trocador de calor aletado. Como esperado, é perceptível a existência de um ponto ótimo tanto para o número de aletas quanto para a espessura dessas, visto que a temperatura máxima atinge um ponto de inflexão e possui uma temperatura superior para os casos com menos e mais aletas e com menor e maior espessura.

Na Figura 17, é apresentada a influência da variação dos parâmetros geométricos do dissipador de calor aletado no número de Nusselt relacionado ao problema de resfriamento. Pode ser observado a redução do número de Nusselt com o aumento das variáveis. Contudo, para o número de aletas e para a espessura das aletas, a redução do número de Nusselt ocorre de forma menos acentuada no início.

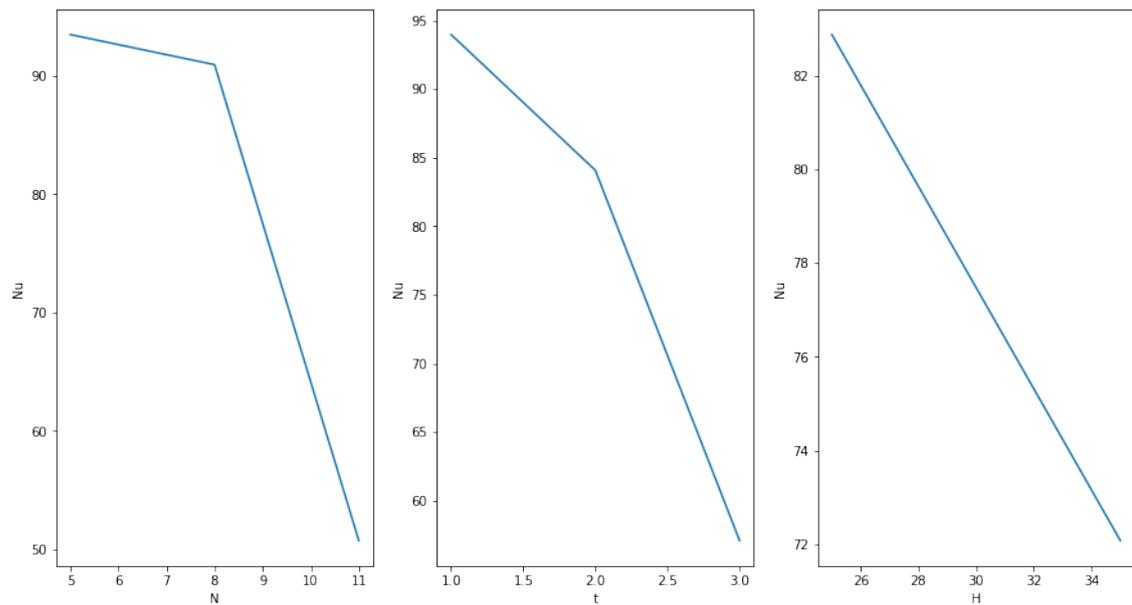
A Figura 18 mostra a influência de cada variável geométrica em análise na resistência térmica do dissipador de calor aletado. O comportamento é similar ao comportamento encontrado para temperatura máxima atingida pelo trocador de calor com aletas planas aplicado no resfriamento de eletroeletrônicos.

Figura 16 – Efeito das variáveis geométricas na temperatura máxima



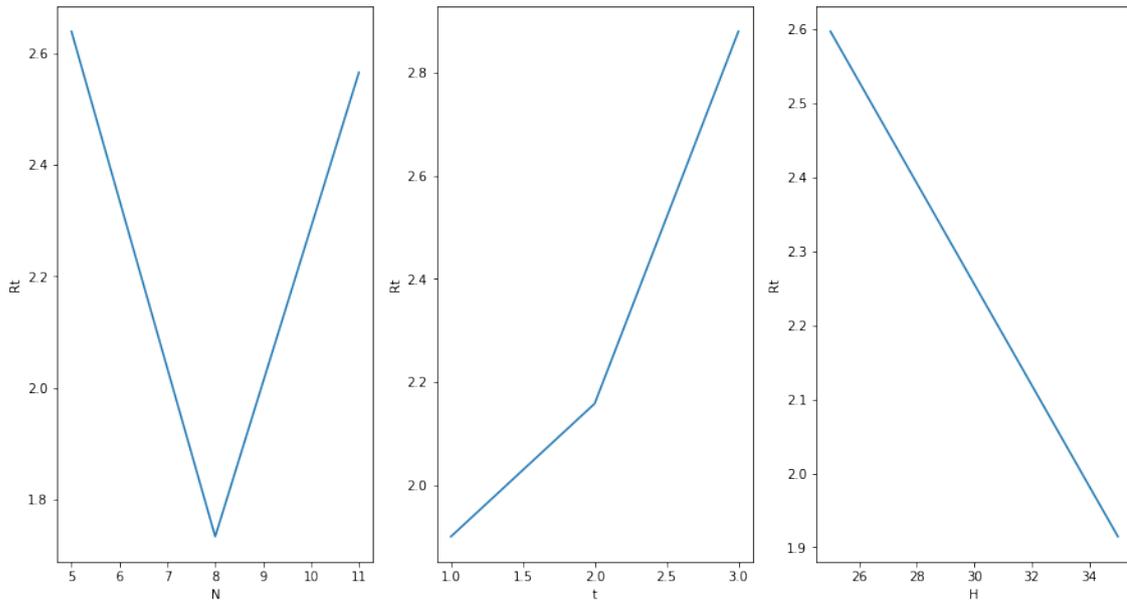
Fonte: autoria própria.

Figura 17 – Efeito das variáveis geométricas no Número de Nusselt



Fonte: autoria própria.

Figura 18 – Efeito das variáveis geométricas na resistência térmica



Fonte: autoria própria.

4.3 MODELOS DE APRENDIZADO DE MÁQUINA

Após realizar o escalonamento dos dados de entrada utilizando o banco de dados gerado pelas simulações numéricas em programa de CFD para os cenários escolhidos, os modelos de Aprendizado de Máquina, citados na Seção 3.4, foram testados e os modelos com resultados mais próximos da resposta obtida em simulação numérica, passaram por um processo de ajuste fino em seus parâmetros para aumentar a precisão. Como as variáveis de resposta foram tratadas de forma independente, um modelo que obteve boa precisão para uma variável pode não ter tido o mesmo desempenho para as demais.

Para a previsão da temperatura máxima, os melhores modelos foram: *Random Forest Regressor* (RFR) e o modelo de Rede Neural Artificial com o Keras, expostos na Tabela 8. Os desvios associados estão entre parênteses.

O modelo *Random Forest Regressor* obteve o melhor resultado quando treinado com 3000 estimadores e utilizando o erro absoluto como critério de avaliação. A Rede Neural Artificial foi treinada com três entradas, duas camadas ocultas de 1536 neurônios cada, e uma saída. Em todas as camadas, a ativação escolhida foi a sigmoide, com otimizador "Adam" e Erro Quadrático Médio como métrica de perda. Esta ativação foi empregada por fornecer bons resultados e por restringir a saída entre valores fixos.

Tabela 8 – Previsões da temperatura máxima [°C] para cada modelo

Case	Resposta	RFR ($\Delta Temperatura$)	Keras ($\Delta Temperatura$)	Média ($\Delta Temperatura$)
1	76,30	85,45 (11,99%)	87,17 (14,25%)	86,31 (13,12%)
2	98,76	98,26 (0,51%)	105,09 (6,41%)	101,68 (2,96%)
3	94,70	95,42 (0,76%)	89,05 (5,97%)	92,24 (2,60%)

Fonte: autoria própria.

Para a previsão do número de Nusselt, os modelos que apresentaram o melhor desempenho foram: *Decision Tree Regressor* (DTR) e o modelo de Rede Neural Artificial do Keras. Uma forma de unificar os modelos foi por meio de um Método *Ensemble* (DIETTERICH, 2000) combinando os resultados individuais dos modelos por meio da média. Os valores do número de Nusselt previstos por cada um dos modelos e a média entre eles estão na Tabela 9. Além disso, entre parênteses, estão apresentados os desvios associados à previsão feita pelo modelo e o resultado esperado.

O modelo de *Decision Tree Regressor* foi treinado com seus parâmetros inalterados, utilizando o erro quadrático médio como critério para avaliar a qualidade das ramificações. Por último, o modelo de Rede Neural Artificial criado por meio do Keras foi desenvolvido a partir do zero. Esse modelo conta com uma entrada de três variáveis, duas camadas ocultas com 256 neurônios cada, e uma saída. Em todas as camadas, a ativação escolhida foi sigmoide, o otimizador empregado foi o "Adam" e a métrica de perda foi o Erro Quadrático Médio.

Tabela 9 – Previsões do Número de Nusselt para cada modelo

Case	Resposta	DTR ($\Delta Nusselt$)	Keras ($\Delta Nusselt$)	Média ($\Delta Nusselt$)
1	98,34	102,00 (3,72%)	95,08 (3,32%)	98,54 (0,20%)
2	89,62	93,30 (4,11%)	99,61 (11,15%)	96,46 (7,63%)
3	31,47	31,00 (1,49%)	42,23 (34,19%)	36,32 (15,41%)

Fonte: autoria própria.

Finalmente, para a previsão da resistência térmica, os melhores modelos foram: *Random Forest Regressor* (RFR), Regressão por Vetores Suporte (SVR) e o modelo de Rede Neural Artificial com o Keras. Os resultados estão apresentados na Tabela 10. Entre parênteses, o erro de cada previsão está mostrado.

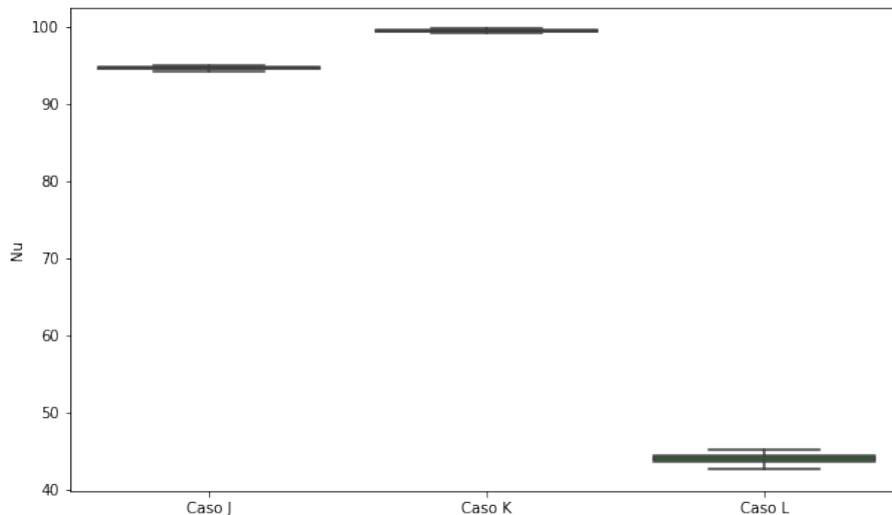
O modelo *Random Forest Regressor* foi treinado a partir de 5000 estimadores distintos e utilizando o erro absoluto como critério de avaliação. O modelo *Support Vector Machine* foi treinado com um *kernel* do tipo sigmoide e um C , o parâmetro de regularização, igual a 3. O modelo de Redes Neurais Artificiais foi treinado com duas camadas ocultas, com 1280 neurônios cada, e uma saída. A ativação "sigmoide" foi empregada e a métrica de perda utilizada foi o Erro Quadrático Médio.

Tabela 10 – Previsões da resistência térmica [°C/W] para cada modelo

Case	Resposta	RFR (ΔR_t)	SVR (ΔR_t)	Keras (ΔR_t)	Média (ΔR_t)
1	1,95	1,94 (0,37%)	1,55 (20,54%)	2.00 (2,56%)	1,83 (6,15%)
2	2,99	2,39 (20,18%)	2,53 (15,45%)	2.63 (12,04%)	2,51 (16,05%)
3	2,90	2,61 (9,92%)	2,84 (1,97%)	2.46 (15,17%)	2,64 (8,97%)

Fonte: autoria própria.

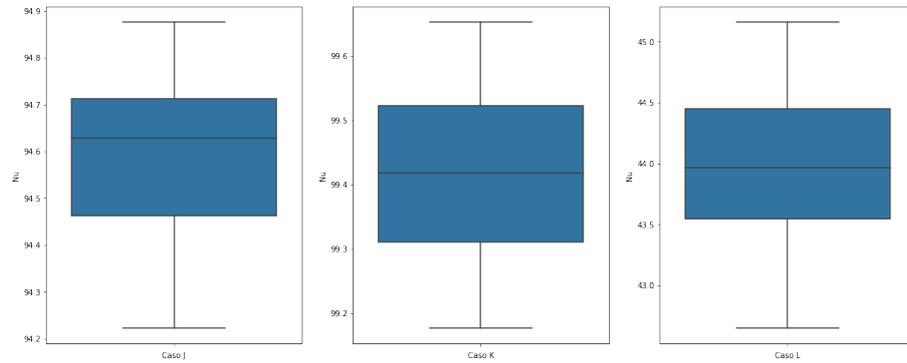
Figura 19 – Variações dos modelos para o número de Nusselt



Fonte: autoria própria.

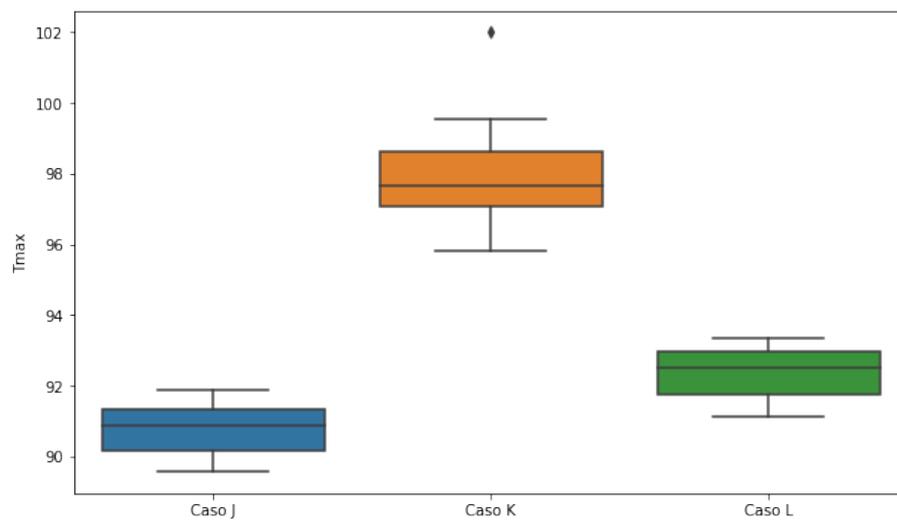
Os modelos de Redes Neurais foram criados 30 vezes cada com os mesmos parâmetros e as estimativas de cada modelo para as três combinações expostas na Tabela 3 foram armazenadas. O objetivo foi analisar se os parâmetros estabelecidos resultavam em um bom modelo mesmo sendo iniciado de forma aleatória diversas vezes, resultando em modelos finais levemente diferentes. Foram utilizados gráficos do tipo *Boxplot* para representar as variações dos modelos. Para o número de Nusselt, a Figura 19 representa todos os três cenários enquanto a Figura 20 apresenta cada caso de forma individual.

Figura 20 – Variações dos modelos para o número de Nusselt de forma individual



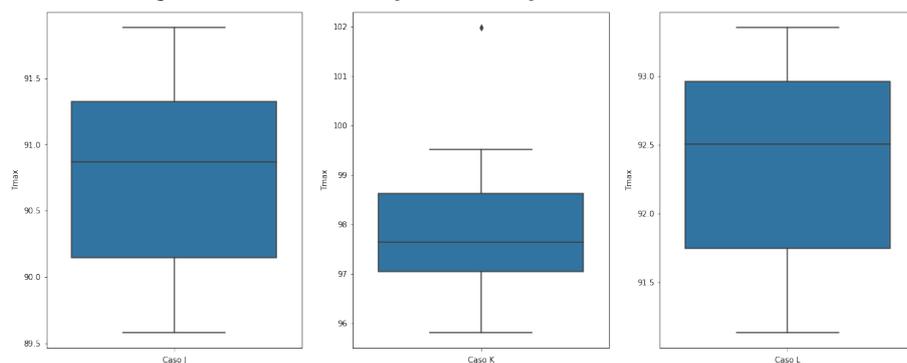
Fonte: autoria própria.

Figura 21 – Variações dos modelos para a temperatura máxima



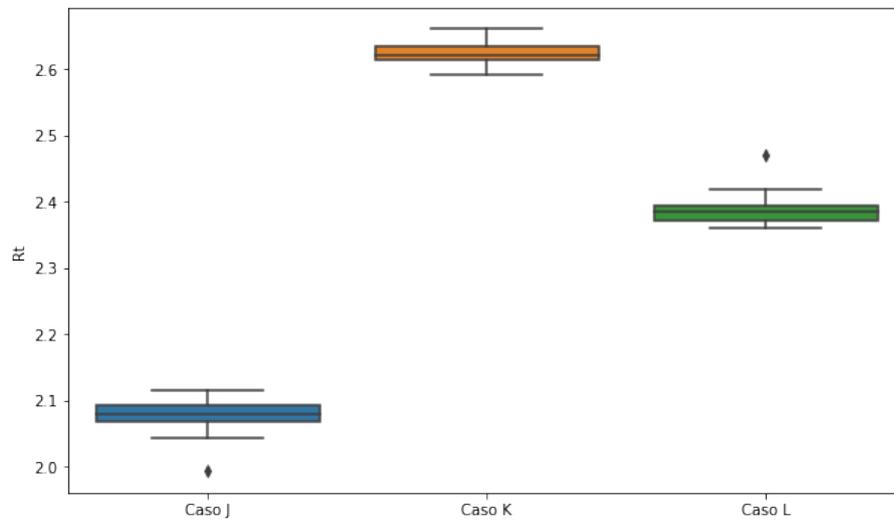
Fonte: autoria própria.

Figura 22 – Variações dos modelos para a temperatura máxima de forma individual



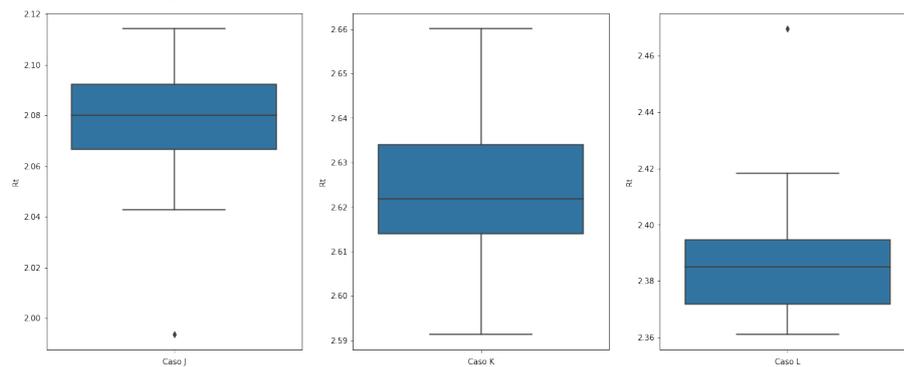
Fonte: autoria própria.

Figura 23 – Variações dos modelos para a resistência térmica



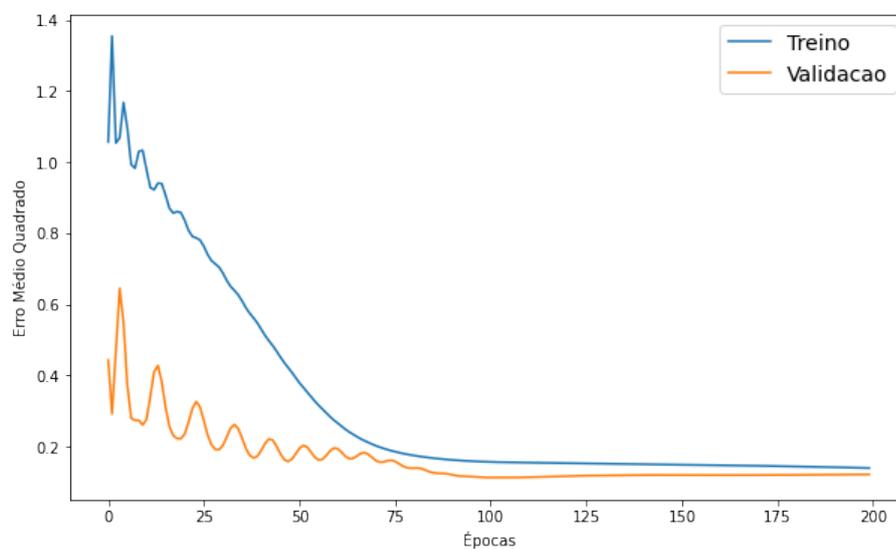
Fonte: autoria própria.

Figura 24 – Variações dos modelos para a resistência térmica de forma individual

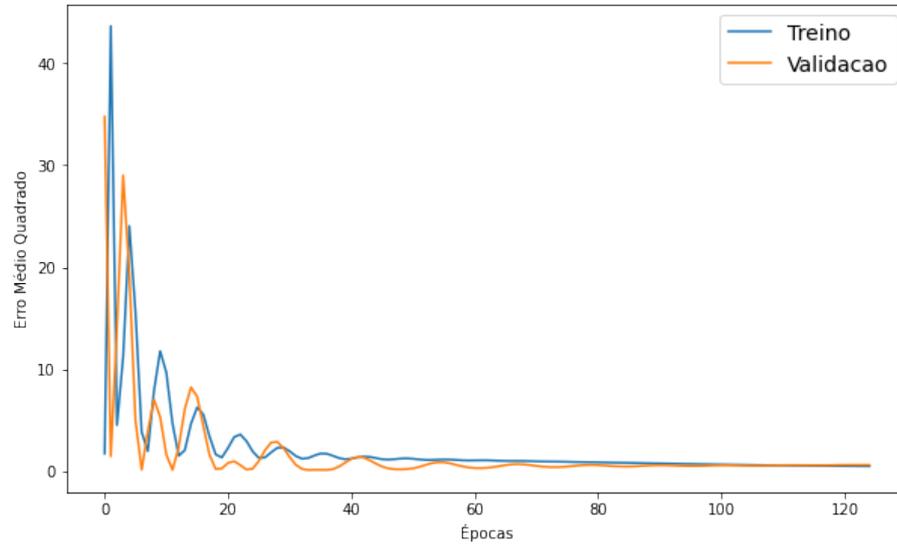


Fonte: autoria própria.

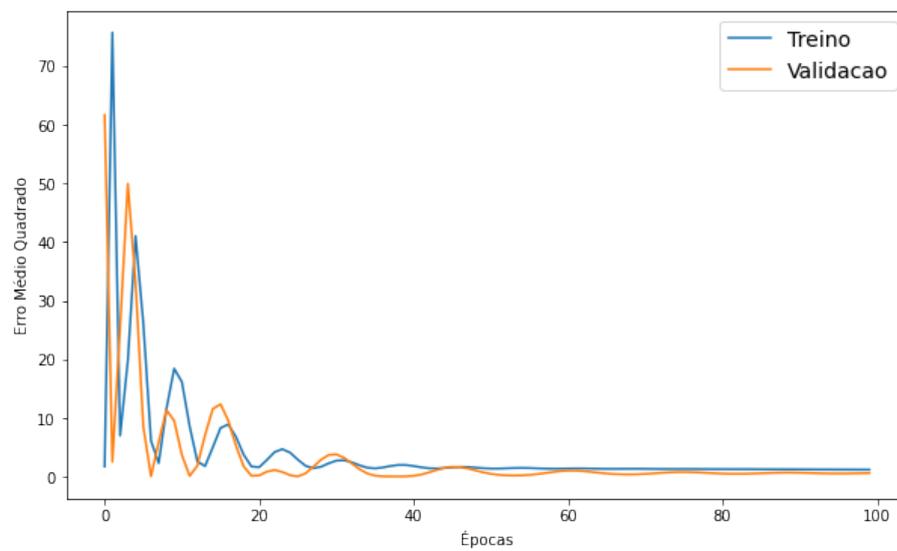
Figura 25 – Erro Médio Quadrado para o número de Nusselt em relação às épocas



Fonte: autoria própria.

Figura 26 – Erro Médio Quadrado para a Resistência Térmica em relação às épocas

Fonte: autoria própria.

Figura 27 – Erro Médio Quadrado para a Temperatura Máxima em relação às épocas

Fonte: autoria própria.

De forma semelhante, para a temperatura máxima, as Figuras 21 e 22 expressam as variações de todos os cenários e os mesmos de forma separada. Para a resistência térmica, as Figuras 23 e 24 exploram as mesmas variações.

É possível identificar pontos *outliers*, ou valores atípicos, para os modelos de temperatura máxima e resistência térmica, mas não para o número de Nusselt. Além disso, foi realizado um estudo estatístico para entender se os dados gerados possuíam uma distribuição Gaussiana. Os resultados são dispostos na Tabela 11. Neste caso, a Hipótese Nula é que os dados vêm de uma distribuição normal, portanto, valores de $p < 0,05$ rejeitam a hipótese nula e implicam que aquele conjunto não vem de uma distribuição normal. Em dois casos na Tabela 11 é possível dizer que a Hipótese Nula é rejeitada.

Tabela 11 – Valor p para cada caso e variável de saída

Case	Tmax	Nu	Rt
Caso J	0,077	0.357	0.333
Caso K	0,003	0.916	0.017
Caso L	0,085	0.347	0.071

Fonte: autoria própria.

Ademais, foi analisado a convergência dos modelos das Redes Neurais. Para isso, os valores de Erro Médio Quadrado para o conjunto de treino e validação foram expostos graficamente por cada época de treinamento. As Figuras 25, 26 e 27 expõem as convergências de cada modelo. Além de convergir entre 100 e 200 iterações, em todos os três modelos é possível observar que nenhum apresenta o sobreajuste, definido pelo excesso de precisão no grupo de treino e uma conseqüente piora no desempenho do grupo de validação.

O resultado do R-quadrado obtido para cada modelo, separados pela variável alvo, é mostrado na Tabela 12. A divergência percentual entre os valores da temperatura máxima do dissipador de calor aletado, do número de Nusselt e da resistência térmica encontrados nas simulações numéricas e os valores previstos pelos modelos de Aprendizado de Máquina são apresentados nas Tabelas 8, 9 e 10.

Como alguns modelos de Aprendizado de Máquina predizem certas regiões de forma melhor do que outras, alguns processos podem ser empregados para combinar

Tabela 12 – R-quadrado por modelo por variável de saída

Saída	DTR	RFR	SVR	Keras
Tmax	-	0,705	-	0,299
Nu	0,990	-	-	0,914
Rt	-	0,331	0,436	0,513

Fonte: autoria própria.

mais de um modelo e gerar um resultado mais balanceado. Como pode ser visto na Tabela 9, a média dos resultados fornecidos pelos três modelos resulta em um valor mais estável e próximo do resultado real. Para a média entre os modelos que estimam a resistência térmica, é possível identificar a redução nos altos valores de erros, se comparados com os modelos individuais.

Uma das vantagens dos modelos *Decision Tree Regressor* e *Random Forest Regressor* é poder acessar a importância de cada variável para aquele modelo. Visto que todos os modelos contam com algum desses, a Tabela 13 ilustra como a altura, espessura e número de aletas impactam no resultado do desempenho térmico das diferentes configurações do dissipador de calor aletado. É possível observar que, para o número de Nusselt, cujo modelo possui o melhor R-quadrado, a altura da aleta não possui grande influência no resultado e o número de aletas possui a maior relevância. Também foi identificada uma forte semelhança entre as importâncias das variáveis na previsão da temperatura máxima e da resistência térmica. Sendo que, nesses casos, a altura das aletas é mais relevante do que no caso anterior, de previsão do número de Nusselt.

Tabela 13 – Importância das variáveis

Saída	H	t	N
Tmax	0,211	0,382	0,406
Nu	0,058	0,333	0,609
Rt	0,210	0,332	0,457

Fonte: autoria própria.

Os modelos de Aprendizado de Máquina, após serem treinados, foram salvos em arquivos separados para serem importados e utilizados em outras estimações, sem a necessidade de novo treinamento. Também, os modelos responsáveis pela padronização dos dados foram salvos de forma separada para tratar dos dados antes desses serem aplicados aos demais modelos.

Todos os códigos criados no trabalho foram disponibilizados em um repositório no GitHub e pode ser acessado em: [Repositório de Códigos e Imagens](#).

5 CONCLUSÕES

Neste trabalho foi avaliado o uso de técnicas de inteligência computacional para um estudo teórico-numérico de otimização de dissipadores de calor aletados utilizados no resfriamento de equipamentos eletroeletrônicos. Com o uso de modelagem numérica, validado com dados experimentais encontrados na literatura, um banco de dados foi criado para treinamento e teste de algoritmos de Aprendizado de Máquina capazes de prever o comportamento de índices de desempenho como temperatura máxima atingida, número de Nusselt e resistência térmica com alterações na geometria.

Para a análise de comportamento desses índices quando há alteração de altura, espessura e número de aletas do dissipador de calor aletado, os dados necessários para o treinamento de tais algoritmos precisam cobrir uma grande área de comportamento do sistema em que são aplicados. Para tal, foi usado a técnica de Planejamento de Experimentos (DOE) chamada *Generalized Subset Designs* (GSD), a partir da Biblioteca de linguagem de programação em Python chamada PyDOE2, obtendo assim as combinações de geometria das quais os dados são necessários. De um total de 18 possíveis cenários, nove foram escolhidos para essa representação, nomeados Casos A até I.

Definido os cenários cujos dados são necessários, o próximo passo foi a modelagem numérica dos mesmos. Para isso, foi utilizado o programa comercial CFD Ansys/Fluent. Para que os dados obtidos por esse método fossem confiáveis, foi feita validação de configurações do sistema usando os dados experimentais obtidos por Maschietto (2018). Para tal, primeiramente foi realizado o estudo de refinamento de malha até que o desvio de resultados estivesse dentro da casa de 1,2%, selecionando uma grade computacional 3D não-uniforme apropriada. Com relação ao estudo das configurações dos cenários, as simulações numéricas utilizando o programa de CFD tiveram o maior desvio na temperatura máxima de 7,34%, valores similares ao desvio máximo de 7,8% encontrado no trabalho de referência. Para o número de Nusselt, esse desvio foi de até 20,9%, dentro do patamar de até 25% tomado como referência na literatura.

Para que o treinamento dos algoritmos pudesse ser testado, outros três cenários, chamados de Casos J, K e L, foram selecionados para simulação numérica e geração do banco. Os resultados numéricos obtidos de cada cenário para a geração do banco

de dados foram: temperatura máxima atingida pelo dissipador aletado, o número de Nusselt e resistência térmica.

O método de DOE, após selecionar as combinações de variáveis a serem simuladas, também foi empregado para analisar o comportamento de cada elemento geométrico, uma vez que a seleção de casos englobou a variação de todas elas. Como observado nas Figuras 16, 17 e 18, as variáveis escolhidas impactam todos os valores de saída e pode ser constatada a existência de um ponto ótimo tanto para o número de aletas quanto para a espessura. Embora o DOE aponte a existência de um ponto ótimo entre os extremos, devido à restrição do número de experimentos, não é possível, contudo, dizer qual é o ponto ótimo absoluto. Apenas é possível dizer ser o melhor dentre os cenários selecionados. Apesar do objetivo desse trabalho não ser encontrar o ponto ótimo, a metodologia apresentada e os códigos desenvolvidos podem ser aperfeiçoados para esse propósito.

Para criação dos modelos de Aprendizado de Máquina, as três principais bibliotecas de linguagem de programação Python utilizadas foram: *Statsmodels*, *Scikit-Learn* e *Tensorflow*. Ao todo, seis diferentes modelos foram testados em cada variável, sendo eles: *Decision Tree Regressor*, *Random Forest Regressor*, *Linear Regression*, *Support Vector Machine*, *Perceptron* Múltiplas Camadas e uma Rede Neural utilizando o *Keras*.

Para realizar a normalização dos dados, o *StandardScaler* foi empregado em todos os casos. E para mensurar a precisão dos modelos, a métrica R-quadrado foi calculada, em especial por não ter sido utilizada como métrica de perda na criação de nenhum modelo. Outra métrica utilizada foi o desvio entre a previsão de cada modelo e o valor real da simulação. Nas Tabelas 8, 9 e 10, foi descrito entre parênteses o erro de cada caso.

Com os nove cenários escolhidos, modelos de Aprendizado de Máquina foram treinados para estimar individualmente cada variável de saída. Esses modelos foram testados em três pontos distintos que não haviam sido fornecidos para o treinamento dos modelos. Os melhores resultados se encontraram na previsão do número de Nusselt, com R-quadrado chegando a 0,990 no melhor modelo. Contudo, houve uma deficiência na capacidade do algoritmo prever resistência térmica, onde o maior R-quadrado foi de apenas 0,513.

A combinação de modelos de Aprendizado de Máquina, feita nesse trabalho por meio da média de resultados, se provou eficiente para reduzir tendências que modelos

individuais pudessem ter e, assim, a combinação entre modelos possibilitou previsões, por vezes menos assertivas; porém, mais estáveis. O método apresentado se mostrou válido para seleção de combinações de variáveis, para interpretação das variáveis e para a predição de resultados, mesmo utilizando um pequeno conjunto de dados para treinamento. Ressalta-se que, em alguns modelos, como o *Decision Tree Regressor*, a pequena quantidade de amostras pode ter levado a algum sobreajuste. A ampliação dos dados de treino poderia ser um método para solucionar esse problema.

Recomenda-se, para trabalhos futuros, a abordagem da mesma metodologia de forma mais generalizada, com variáveis adicionais e mais divisões para cada variável. Dessa forma, desenvolvendo um modelo que aborde mais aletas e que gere um maior entendimento sobre cada uma das variáveis. Também recomenda-se expandir o presente trabalho para encontrar os pontos ótimos de combinação entre as variáveis geométricas. Também é sugerida a verificação de como tais modelos se comportam fora dos limites estabelecidos no presente trabalho para cada variável utilizada. Tanto para valores no interior do cubo representado na Figura 5, quanto para os valores externos a ele. Finalmente, no âmbito dos modelos de Aprendizado de Máquina, recomenda-se testes mais aprofundados sobre a acurácia dos preditores gerados, geração de modelos utilizando outras métricas de perda, alteração do número de camadas e neurônios, avaliação de seus desempenhos e o melhor estudo sobre combinação de modelos, visando reduzir ruídos e tendências que alguns desses possam apresentar.

REFERÊNCIAS

- ALVES, T. A.; ALTEMANI, C. A. An invariant descriptor for heaters temperature prediction in conjugate cooling. **International Journal of Thermal Sciences**, v. 58, p. 92–101, 2012. ISSN 1290-0729. DOI: 10.1016/j.ijthermalsci.2012.03.007. Disponível em: <https://www.sciencedirect.com/science/article/pii/S129007291200097X>.
- BOYD, A.; SUN, D. L. **salmon: A Symbolic Linear Regression Package for Python**. [S. l.: s. n.], 2021. arXiv: 1911.00648 [stat.CO].
- CASS, S. The 2018 top programming languages. **IEEE Spectrum**, v. 31, p. 1, 2018.
- ÇENGEL, Y. A.; GHAJAR, A. J. **Transferência de calor e massa : uma abordagem prática**. [S. l.]: AMGH, 2012. ISBN 9788580551273. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=cat07269a&AN=utfr.259989&lang=pt-br&site=eds-live&scope=site>.
- CHANG, C.-C.; LIN, C.-J. LIBSVM: A Library for Support Vector Machines. **ACM Trans. Intell. Syst. Technol.**, Association for Computing Machinery, New York, NY, USA, v. 2, n. 3, mai. 2011. ISSN 2157-6904. DOI: 10.1145/1961189.1961199.
- D'AGOSTINO, R. B. An Omnibus Test of Normality for Moderate and Large Size Samples. **Biometrika**, [Oxford University Press, Biometrika Trust], v. 58, n. 2, p. 341–348, 1971. ISSN 00063444. Disponível em: <http://www.jstor.org/stable/2334522>. Acesso em: 3 jul. 2022.
- DAS, D.; DWIVEDI, A. Parametric Optimization of Heat Transfer from Triangular Fin Array Within a Rectangular Enclosure Using Design of Experiment (DOE): A Comparative Analysis. **Journal of The Institution of Engineers (India): Series C**, v. 94, nov. 2013. DOI: 10.1007/s40032-013-0087-8.
- DIETTERICH, T. G. Ensemble Methods in Machine Learning. In: MULTIPLE Classifier Systems. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000. P. 1–15. ISBN 978-3-540-45014-6.
- FERREIRA, S. *et al.* Box-Behnken design: An alternative for the optimization of analytical methods. **Analytica Chimica Acta**, v. 597, n. 2, p. 179–186, 2007. ISSN 0003-2670. DOI: 10.1016/j.aca.2007.07.011. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0003267007011671>.
- GERON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2nd. [S. l.]: O'Reilly Media, Inc., 2019. ISBN 1492032646.
- GÜREŞÇİ, K. *et al.* Numerical analysis with experimental comparison in duct flow using optimized heat sinks. **Journal of Radiation Research and Applied Sciences**, v. 11, n. 2, p. 116–123, 2018. Advances in Natural and Applied Sciences. ISSN 1687-8507.

DOI: 10.1016/j.jrras.2017.10.008. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S1687850717300559>.

KARNA, S. K.; SAHAI, R. *et al.* An overview on Taguchi method. **International journal of engineering and mathematical sciences**, v. 1, n. 1, p. 1–7, 2012.

KUMAR, V.; BARTARIA, D. V. CFD analysis of an elliptical pin fin heat sink using ansys fluent v12. 1. **International Journal of Modern Engineering Research (IJMER)**, Citeseer, v. 3, n. 2, p. 1115–1122, 2013.

LUJAN-MORENO, G. A. *et al.* Design of experiments and response surface methodology to tune machine learning hyperparameters, with a random forest case-study. **Expert Systems with Applications**, v. 109, p. 195–205, 2018. ISSN 0957-4174. DOI: 10.1016/j.eswa.2018.05.024. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0957417418303178>.

MARTIN ABADI *et al.* **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. [S. l.: s. n.], 2015. Software available from tensorflow.org. Disponível em: <https://www.tensorflow.org/>.

MASCHIETTO, V. C. L. Investigação experimental e análise numérica da transferência de calor em um dissipador de calor aletado, set. 2018. Disponível em:
<http://repositorio.utfpr.edu.br/jspui/handle/1/3561>.

PAKROUH, R. *et al.* A numerical method for PCM-based pin fin heat sinks optimization. **Energy Conversion and Management**, v. 103, p. 542–552, 2015. ISSN 0196-8904. DOI: 10.1016/j.enconman.2015.07.003. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0196890415006548>.

PATANKAR, S. **Numerical Heat Transfer and Fluid Flow**. [S. l.]: Hemisphere Publishing Corporation, 1980. (Electro Skills Series). ISBN 9780070487406. Disponível em: <https://books.google.com.br/books?id=N2MVAQAIAAJ>.

PEDREGOSA, F. *et al.* Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

SEABOLD, S.; PERKTOLD, J. Statsmodels: Econometric and Statistical Modeling with Python. **Proceedings of the 9th Python in Science Conference**, v. 2010, jan. 2010.

SILVA, I. N. d.; FLAUZINO, R. A.; SPATTI, D. H. **Redes neurais artificiais para engenharia e ciências aplicadas**. [S. l.]: Artliber, 2010. ISBN 9788588098534. Disponível em: <https://search.ebscohost.com/login.aspx?direct=true&db=cat07269a&AN=utfpr.270272&lang=pt-br&site=eds-live&scope=site>.

SOLA, J.; SEVILLA, J. Importance of input data normalization for the application of neural networks to complex industrial problems. **IEEE Transactions on Nuclear Science**, v. 44, n. 3, p. 1464–1468, 1997. DOI: 10.1109/23.589532.

SUROWIEC, I. *et al.* Generalized Subset Designs in Analytical Chemistry. **Analytical Chemistry**, v. 89, n. 12, p. 6491–6497, 2017. PMID: 28497952. DOI: 10.1021/acs.analchem.7b00506.

TAUD, H.; MAS, J. Multilayer Perceptron (MLP). In: **Geomatic Approaches for Modeling Land Change Scenarios**. Edição: María Teresa Camacho Olmedo. Cham: Springer International Publishing, 2018. P. 451–455. ISBN 978-3-319-60801-3. DOI: 10.1007/978-3-319-60801-3_27.

VIRTANEN, P. *et al.* SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. **Nature Methods**, v. 17, p. 261–272, 2020. DOI: 10.1038/s41592-019-0686-2.

YANG, D. *et al.* Numerical and experimental analysis of cooling performance of single-phase array microchannel heat sinks with different pin-fin configurations. **Applied Thermal Engineering**, v. 112, p. 1547–1556, 2017. ISSN 1359-4311. DOI: 10.1016/j.applthermaleng.2016.08.211. Disponível em: <https://www.sciencedirect.com/science/article/pii/S135943111631571X>.

**ANEXO A — LEI N.º 9.610, DE 19 DE FEVEREIRO DE
1998: DIREITOS AUTORAIS / DISPOSIÇÕES PRELIMINARES**



Presidência da República
Casa Civil
Subchefia para Assuntos Jurídicos

LEI Nº 9.610, DE 19 DE FEVEREIRO DE 1998.

[Mensagem de veto](#)

Altera, atualiza e consolida a legislação sobre direitos autorais e dá outras providências.

[Regulamento](#)

O PRESIDENTE DA REPÚBLICA Faço saber que o Congresso Nacional decreta e eu sanciono a seguinte Lei:

Título I

Disposições Preliminares

Art. 1º Esta Lei regula os direitos autorais, entendendo-se sob esta denominação os direitos de autor e os que lhes são conexos.

Art. 2º Os estrangeiros domiciliados no exterior gozarão da proteção assegurada nos acordos, convenções e tratados em vigor no Brasil.

Parágrafo único. Aplica-se o disposto nesta Lei aos nacionais ou pessoas domiciliadas em país que assegure aos brasileiros ou pessoas domiciliadas no Brasil a reciprocidade na proteção aos direitos autorais ou equivalentes.

Art. 3º Os direitos autorais reputam-se, para os efeitos legais, bens móveis.

Art. 4º Interpretam-se restritivamente os negócios jurídicos sobre os direitos autorais.

Art. 5º Para os efeitos desta Lei, considera-se:

I - publicação - o oferecimento de obra literária, artística ou científica ao conhecimento do público, com o consentimento do autor, ou de qualquer outro titular de direito de autor, por qualquer forma ou processo;

II - transmissão ou emissão - a difusão de sons ou de sons e imagens, por meio de ondas radioelétricas; sinais de satélite; fio, cabo ou outro condutor; meios óticos ou qualquer outro processo eletromagnético;

III - retransmissão - a emissão simultânea da transmissão de uma empresa por outra;

IV - distribuição - a colocação à disposição do público do original ou cópia de obras literárias, artísticas ou científicas, interpretações ou execuções fixadas e fonogramas, mediante a venda, locação ou qualquer outra forma de transferência de propriedade ou posse;

V - comunicação ao público - ato mediante o qual a obra é colocada ao alcance do público, por qualquer meio ou procedimento e que não consista na distribuição de exemplares;

VI - reprodução - a cópia de um ou vários exemplares de uma obra literária, artística ou científica ou de um fonograma, de qualquer forma tangível, incluindo qualquer armazenamento permanente ou temporário por meios eletrônicos ou qualquer outro meio de fixação que venha a ser desenvolvido;

VII - contrafação - a reprodução não autorizada;

VIII - obra:

- a) em co-autoria - quando é criada em comum, por dois ou mais autores;
- b) anônima - quando não se indica o nome do autor, por sua vontade ou por ser desconhecido;
- c) pseudônima - quando o autor se oculta sob nome suposto;
- d) inédita - a que não haja sido objeto de publicação;
- e) póstuma - a que se publique após a morte do autor;
- f) originária - a criação primígena;
- g) derivada - a que, constituindo criação intelectual nova, resulta da transformação de obra originária;

h) coletiva - a criada por iniciativa, organização e responsabilidade de uma pessoa física ou jurídica, que a publica sob seu nome ou marca e que é constituída pela participação de diferentes autores, cujas contribuições se fundem numa criação autônoma;

i) audiovisual - a que resulta da fixação de imagens com ou sem som, que tenha a finalidade de criar, por meio de sua reprodução, a impressão de movimento, independentemente dos processos de sua captação, do suporte usado inicial ou posteriormente para fixá-lo, bem como dos meios utilizados para sua veiculação;

IX - fonograma - toda fixação de sons de uma execução ou interpretação ou de outros sons, ou de uma representação de sons que não seja uma fixação incluída em uma obra audiovisual;

X - editor - a pessoa física ou jurídica à qual se atribui o direito exclusivo de reprodução da obra e o dever de divulgá-la, nos limites previstos no contrato de edição;

XI - produtor - a pessoa física ou jurídica que toma a iniciativa e tem a responsabilidade econômica da primeira fixação do fonograma ou da obra audiovisual, qualquer que seja a natureza do suporte utilizado;

XII - radiodifusão - a transmissão sem fio, inclusive por satélites, de sons ou imagens e sons ou das representações desses, para recepção ao público e a transmissão de sinais codificados, quando os meios de decodificação sejam oferecidos ao público pelo organismo de radiodifusão ou com seu consentimento;

XIII - artistas intérpretes ou executantes - todos os atores, cantores, músicos, bailarinos ou outras pessoas que representem um papel, cantem, recitem, declamem, interpretem ou executem em qualquer forma obras literárias ou artísticas ou expressões do folclore.

XIV - titular originário - o autor de obra intelectual, o intérprete, o executante, o produtor fonográfico e as empresas de radiodifusão. [\(Incluído pela Lei nº 12.853, de 2013\)](#)

Art. 6º Não serão de domínio da União, dos Estados, do Distrito Federal ou dos Municípios as obras por eles simplesmente subvencionadas.

...

Texto completo da lei:

