

# Machine Learning na Predição da Temperatura de Isolamento de Motores de Indução

*Machine Learning in the Prediction of the Insulation Temperature of Inductions Motors*

André Luiz Refulia<sup>1</sup>

 [orcid.org/0009-0002-8241-1067](https://orcid.org/0009-0002-8241-1067)

<sup>1</sup>Faculdade de Tecnologia Senai Roberto Simonsen, São Paulo, Brasil. E-mail: [andrerefulia100@gmail.com](mailto:andrerefulia100@gmail.com)

<sup>2</sup>Faculdade de Tecnologia Senai Roberto Simonsen, São Paulo, Brasil. E-mail: [doublas.baquião@sp.senai](mailto:doublas.baquião@sp.senai)

DOI: 10.25286/repa.v10i1.2508

Esta obra apresenta Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.

Como citar este artigo pela NBR 6023/2018: André Luiz Refulia; Douglas José Baquião Ribeiro. Machine Learning in the Prediction of the Insulation Temperature of Inductions Motors. Revista de Engenharia e Pesquisa Aplicada, v.10, n. 1, p. 33-42, 2025.

Douglas José Baquião Ribeiro<sup>2</sup>

 [orcid.org/0000-0002-4995-3799](https://orcid.org/0000-0002-4995-3799)

## RESUMO

A operação de um motor com temperatura acima do limite da sua classe térmica pode reduzir significativamente a vida útil da isolação do enrolamento e, conseqüentemente, a vida útil do próprio motor. Com as redes de comunicação industriais aliadas ao processo de transformação digital, tornou-se possível coletar uma série de dados de operação e funcionamento dos motores de indução, direcionando-os a algoritmos de *Machine Learning* para produção de resultados, como a predição da temperatura de isolamento do enrolamento de um motor de indução trifásico. Este processo de predição permitirá que os departamentos de manutenção ajam antes que a temperatura ultrapasse um determinado limite. O texto propõe uma metodologia que utiliza e compara diversos algoritmos de *Machine Learning* para regressão, incluindo modelos tradicionais, como *Regressão Linear*, *Ridge* e *Lasso*, além de técnicas, como Redes Neurais e Arvore de Decisão. Também aborda técnicas de *ensemble*, como *Bagging*, *Boosting*, e *Stacking*, para melhorar a precisão e a estabilidade dos modelos, além de aumentar a robustez para tratar outliers. O modelo *Bagging Regressor* foi capaz de prever a temperatura de isolamento do enrolamento, com coeficiente de determinação ( $R^2$  score) de 98%. Para uma temperatura real de 65°C, sua predição foi de 66,2°C, com intervalo de previsão de 64,2°C a 67,2°C.

**PALAVRAS-CHAVE:** Motor de indução; Temperatura de Isolação; Machine Learning.

## ABSTRACT

Operating a motor above its thermal class temperature limit can significantly reduce the insulation life of the winding and, consequently the motor's lifespan. With industrial communication networks combined with the digital transformation process, it has become possible to collect a series of operational data from induction motors and feed it into Machine Learning algorithms to produce results such as the prediction of the insulation temperature of a three-phase induction motor's winding. This prediction process will enable maintenance departments to act before the temperature exceeds a certain limit. The text proposes a methodology that uses and compares various Machine Learning algorithms for regression, including traditional models such as Linear Regression, Ridge, and Lasso, as well as techniques like Neural Network and Decision Trees. It also addresses ensemble techniques such as Bagging Boosting and Stacking to improve the accuracy and stability of the models, as well increase robustness in handling outliers. The Bagging Regressor model was able to predict the winding insulation temperature with a coefficient of determination ( $R^2$  score) of 98%. For a real temperature of 65°C, the prediction was 66,2°C, with a prediction intervalo of 64,2°C to 67,2°C.

**KEY-WORDS:** Induction Motor; Insulation Temperature; Machine Learning.

## 1 INTRODUÇÃO

O investimento em novas tecnologias tem sido uma das principais estratégias utilizadas para o crescimento e consolidação de empresas. Transformar simples dados em informações estratégicas é um dos principais objetivos desses investimentos. As empresas de diversos setores estão focadas em explorar dados para obter vantagens competitivas [1]. Quando esses dados e informações são processados e analisados, eles têm o potencial de revelar insights e conhecimentos valiosos sobre os sistemas de manufatura, oferecendo resultados interpretativos para a tomada de decisões estratégicas [2].

Entre essas novas tecnologias estão os algoritmos de *Machine Learning*, uma tecnologia habilitadora presente na quarta revolução industrial, também conhecida como "indústria 4.0". A indústria 4.0 é caracterizada pela integração de tecnologias digitais avançadas aos processos de produção. O principal objetivo do *Machine Learning* é encontrar padrões em grandes volumes de dados, automatizando a tomada de decisões a partir de predições bem-sucedidas [3]. Lee e colaboradores [4] mencionam que o surgimento da Indústria 4.0 está direcionando mais foco para estratégias de manutenção preditiva voltadas para a redução dos custos de inatividade e o aumento da disponibilidade de equipamentos de manufatura.

Uma das maiores fabricantes de motores elétricos do mundo vem aperfeiçoando, monitorando e analisando dados em motores de indução trifásicos, auxiliando os departamentos de manutenção das empresas a tomarem decisões estratégicas com base em processos de predição. Neste contexto, a proposta da WEG (*Empresa Multinacional Brasileira Fabricante de Motores Elétricos*) é aumentar a confiabilidade, produtividade e disponibilidade de máquinas industriais equipadas com motores de indução.

Recentemente, o aprendizado de máquina tem sido amplamente utilizado em diferentes aplicações na indústria, como operações de manutenção de equipamentos [5,6]. De acordo com Chen et al [5] muitas empresas veem a inteligência artificial, em particular o aprendizado de máquina, como um componente estratégico importante que pode ser utilizado para obter vantagens competitivas. Os mesmos autores concluíram que os algoritmos de aprendizado de máquina tiveram avanços significativos em desempenho e aplicabilidade na manutenção industrial nos últimos anos. Entre as várias áreas de manutenção, a de motores está sendo considerada recentemente e já obtém avanços. A predição da temperatura de isolamento em motores de indução trifásicos é uma área de crescente interesse, devido à importância da manutenção preditiva na prevenção de falhas e na extensão da vida útil dos equipamentos. Diversos estudos têm investigado a

aplicação de técnicas de *Machine Learning* para melhorar a precisão e a eficiência dessas previsões. Esta análise é fundamental para situar nosso trabalho no contexto atual da pesquisa e evidenciar as contribuições e avanços propostos.

A pesquisa de Czerwinski [7] destaca que métodos modernos e altamente eficazes para estimar a temperatura de motores elétricos incluem o aprendizado de máquina e o aprendizado profundo. Sua vantagem inquestionável reside no fato de que, com base nos dados de medição coletados, é possível determinar uma função que mapeia o relacionamento entre os valores das variáveis de entrada e a saída. Algoritmos de regressão linear, Suporte Vector Machine (SVM), árvores de decisão e métodos de ensemble foram utilizados para a modelagem preditiva. A pesquisa obteve resultados promissores na estimativa da temperatura do enrolamento de motores, com a métrica MAPE apresentando um erro inferior a 4,5% e o coeficiente de determinação ( $R^2$ ) acima de 90%.

Conforme Nogay [8], tanto as redes neurais quanto outros métodos de aprendizado de máquina provaram sua eficácia na estimativa da temperatura de motores de indução. Os resultados indicam que o modelo de rede neural artificial (RNA) oferece estimativas confiáveis da temperatura interna do enrolamento do estator. Esse modelo permite determinar as temperaturas em motores testados e avaliar a influência da tensão elétrica e frequência nas temperaturas em estado estacionário. Estudos como os de Kirchgässner [9], que aplicam redes neurais profundas recorrentes e convolucionais (NNs) com conexões residuais, avaliam a viabilidade desses modelos na previsão contínua de temperaturas em motores síncronos de ímã permanente.

As redes neurais, utilizando o *MLP Regressor (Multilayer Perceptron)*, têm se destacado na modelagem de problemas não lineares e complexos. Na pesquisa de Ferraz [10] o *MPL Regressor* foi aplicado no diagnóstico de falhas de máquinas rotativas. A metodologia utilizada incluiu a configuração de um banco experimental para gerar conjuntos de dados representativos de cinco cenários distintos em aplicações com motores elétricos. O processo metodológico envolveu a coleta e limpeza dos dados, a formatação adequada, a geração de atributos a partir dos sinais coletados, bem como a modelagem e a avaliação dos modelos. Os dois modelos que apresentaram os melhores resultados foram o k-NN ( $K = 3$ ) e o MLP (com 100 neurônios em cada camada). Para o modelo *MLP Regressor*, o coeficiente de determinação ( $R^2$ ) alcançou 91%.

O presente estudo aborda todo o processo de coleta, preparação, visualização e análise de dados com objetivo de construir um modelo de *Machine Learning* para prever a temperatura de isolamento do enrolamento de um motor de

indução trifásico. "Um aumento de 8 a 10 graus Celsius acima do limite da classe térmica da temperatura de isolamento pode reduzir a vida útil do enrolamento pela metade" [11]. O objetivo deste processo de predição é antecipar rotinas de manutenção nessas máquinas para garantir que a temperatura de isolamento do enrolamento não ultrapasse o limite da sua classe térmica. "A experiência mostra que a isolação tem uma duração praticamente ilimitada se a temperatura for mantida abaixo do limite da sua classe térmica" [11].

Para análise dos resultados, foi utilizado o coeficiente de determinação  $R^2$  como uma métrica de desempenho, permitindo avaliar a precisão das previsões em relação aos dados observados. Além disso, a análise dos intervalos de previsão se destaca por fornecer uma compreensão mais detalhada sobre a incerteza associada às predições, garantindo que as estimativas estejam não apenas próximas dos valores reais, mas também que incluam variações potenciais, o que é crucial para a tomada de decisões seguras e informadas no contexto da manutenção preditiva.

## 2 COLETA DE DADOS

O conjunto de dados é composto por 10 parâmetros e 231.926 medidas. As medidas foram coletadas a cada dez segundos, totalizando 644 horas de operação do motor em diversas condições operacionais, incluindo variação de velocidade e tempo de funcionamento tanto no sentido horário quanto no anti-horário. Além disso, parâmetros como aceleração, desaceleração e variação de carga na ponta do eixo do motor também foram alterados. Os parâmetros foram organizados em três categorias: operação, sistema de partida e processo no qual o motor está instalado. Estes parâmetros estão apresentados no Quadro 1.

Quadro 1 – Dados Coletados

Dados Coletados		
Dados Operacionais	Dados Sistema de Partida	Dados do Processo
Tempo Sentido Horário Tempo Sentido Anti-Horário Velocidade do Motor	Rampa de Aceleração Rampa de Desaceleração	Frequência Atual do Motor Corrente Atual do Motor Torque Atual do Motor Horas de Operação do Motor

Fonte: Autores, 2024

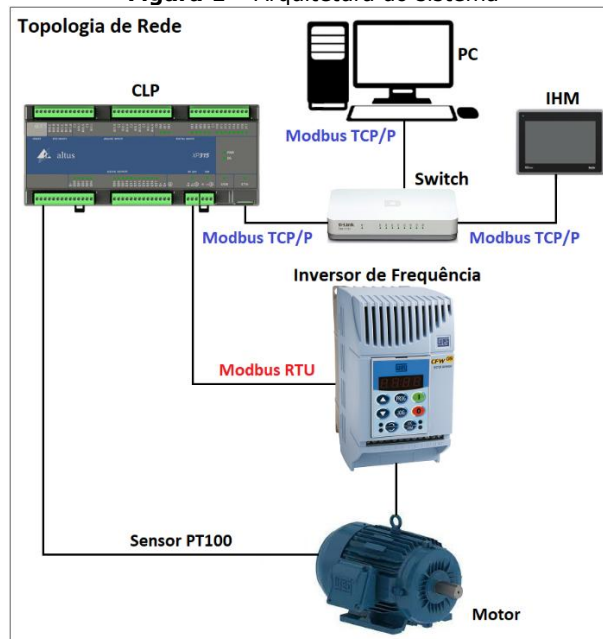
Uma interface gráfica desenvolvida na *IDE Visual Studio*, utilizando a linguagem de programação *C#*, foi responsável pelo processo de coleta dos dados. Após a coleta, os dados foram armazenados em uma base *SQL Server* e, através da linguagem *SQL*, foram exportados para um arquivo.csv, formando o *dataset* utilizado posteriormente pelo algoritmo de *Machine Learning* para seu aprendizado.

O processo de coleta de dados envolve o CLP (*Controlador Lógico Programável*), que envia e recebe informações do inversor de frequência através de uma rede de comunicação industrial

utilizando o protocolo *MODBUS RTU (Remote Terminal Unit)*. O protocolo de comunicação *Modbus* é um protocolo de comunicação serial amplamente utilizado em sistemas de automação e controle industrial [12]. Este intercâmbio inclui o envio de comandos para operação do motor e o recebimento de informações como corrente elétrica, frequência, torque, rampa de aceleração e rampa de desaceleração do motor.

Além dessas informações, dados operacionais provenientes da IHM (*Interface Homem-Máquina*) e a temperatura do motor medida pelo sensor *PT100* são transmitidos para a interface gráfica do computador por meio de uma segunda rede de comunicação industrial no protocolo *MODBUS TCP/IP*. Um sensor *PT100* é um tipo de sensor de temperatura amplamente utilizado em várias aplicações industriais. O "PT" em *PT100* significa Platina (*Platinum*), e o "100" refere-se à resistência nominal do sensor a 0°C, que é de 100 ohms. Este tipo de sensor é conhecido por sua precisão e estabilidade em uma ampla faixa de temperaturas. O protocolo *MODBUS TCP/IP* é uma variante do protocolo *MODBUS* que utiliza a pilha de protocolos *TCP/IP* para comunicação em redes *Ethernet*. Ele permite a comunicação entre dispositivos industriais, como *CLPs*, sistemas de supervisão e aquisição de dados, e dispositivos de automação, através de uma rede *TCP/IP*. Essa abordagem oferece várias vantagens, como maior velocidade de comunicação, capacidade de conectar múltiplos dispositivos em uma única rede, facilidade de implementação e integração com sistemas de *TI (Tecnologia da Informação)* existentes. A arquitetura deste sistema está apresentada na Figura 1.

Figura 1 – Arquitetura do sistema



Fonte: Autores, 2024

### 3 PREPARAÇÃO DOS DADOS

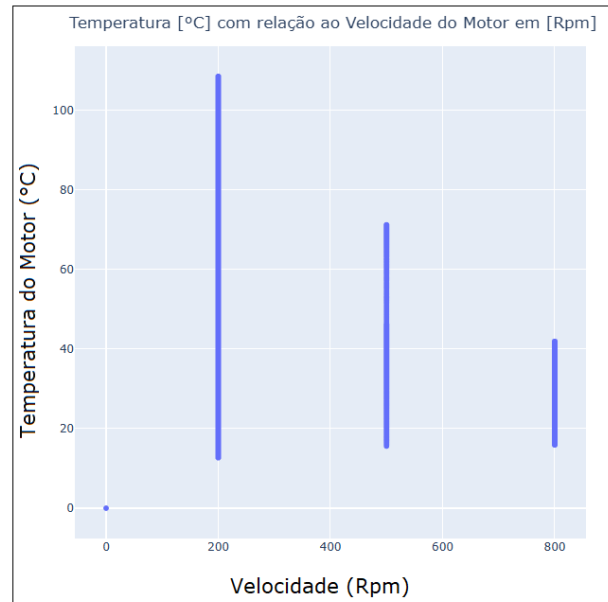
Segundo a literatura acadêmica, um sério problema na mineração de bases de dados industriais é que estas frequentemente contêm dados incompletos ou erroneamente registrados [13] e apesar de existirem diversas maneiras de lidar com *datasets* em tal situação, a literatura não determina qual é o melhor método para todos esses tipos de dados [14]. Alguns procedimentos de imputação são simples e implementados na maioria dos aplicativos estatísticos [15] sendo que, de acordo com Assunção [16] os métodos mais comuns são aqueles que envolvem a remoção ou a substituição desse tipo de dado por alguma medida resumo (média ou mediana).

A coluna corrente atual do motor e torque atual do motor do *dataset* possui dados faltantes, pois durante a coleta desses dados o motor estava em processo de desaceleração para inverter o sentido de rotação. A taxa de ausência para a coluna corrente atual do motor foi 0,3% e a taxa de ausência para a coluna torque atual do motor foi de 2,5%. Os dados faltantes foram imputados utilizando métodos de média e mediana.

### 4 ANÁLISE EXPLORATÓRIA DOS DADOS

A correlação existente entre os parâmetros do *dataset* foi o primeiro ponto observado na análise exploratória. Para avaliar a relação linear entre duas variáveis quantitativas, utilizou-se o coeficiente linear de Pearson, considerando como variável alvo a temperatura de isolamento do enrolamento em relação aos outros parâmetros do *dataset*. A análise do mapa mostrou que a velocidade, a corrente elétrica e o torque do motor possuem uma alta correlação com a temperatura de isolamento do enrolamento, sendo respectivamente: 0,80; 0,72; e 0,85. A velocidade apresentou uma correlação negativa: quanto menor a velocidade, maior é a temperatura de isolamento do enrolamento. Já a corrente elétrica e o torque do motor apresentaram uma correlação positiva: quanto maior a corrente elétrica e o torque do motor, maior é a temperatura de isolamento do enrolamento. O tempo horário, tempo anti-horário, rampa de aceleração, rampa de desaceleração, frequência atual do motor, e horímetro não apresentaram uma forte relação linear com a temperatura de isolamento do enrolamento. As Figuras 2, 3 e 4 apresentam os gráficos bivariados que ilustram as correlações existentes entre velocidade atual do motor, corrente elétrica e torque atual do motor com a temperatura de isolamento do enrolamento.

**Figura 2** – Velocidade e temperatura de isolamento do enrolamento

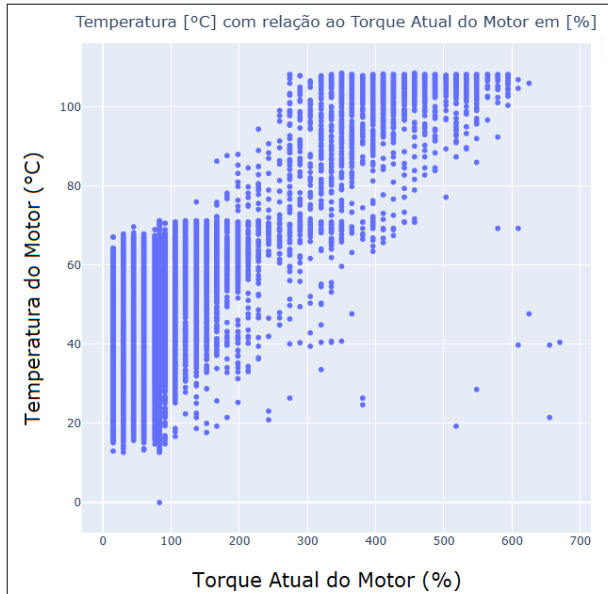


Fonte: Autores, 2024

A Figura 2 apresenta a correlação existente entre a temperatura de isolamento do enrolamento e a velocidade do motor para o mesmo período de trabalho. É possível notar que, na menor velocidade de rotação e com todos os outros parâmetros do *dataset* mantidos constantes, foi observada uma maior amplitude de temperaturas, contemplando tanto os valores mais baixos medidos, quanto os mais altos. Tal variação se reduziu a cada aumento de velocidade de rotação, sendo as rotações de 800 rpm aquelas com menor amplitude térmica, indicando provavelmente maior eficiência na dissipação do calor.

O limite de temperatura depende do tipo de material empregado no enrolamento. Os materiais isolantes e os sistemas de isolamento são agrupados em classes de isolamento e seus respectivos limites de temperatura são definidos pela ABNT NBR 17094. Para o motor em estudo, o limite de temperatura é de 130°C.

**Figura 3** – Torque e a temperatura de isolamento do enrolamento

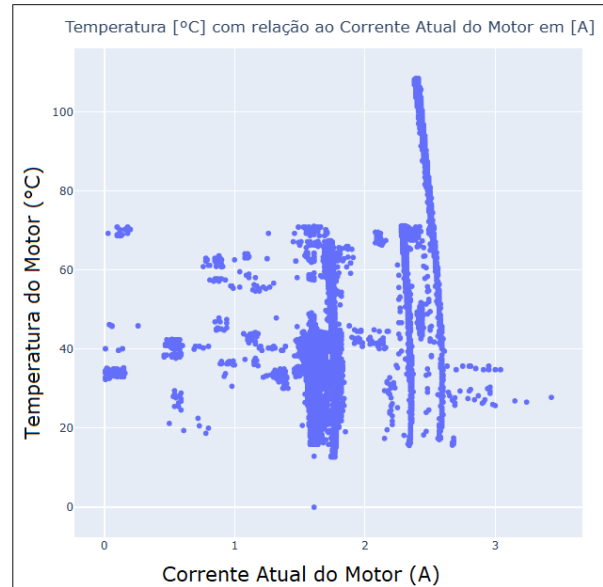


Fonte: Autores, 2024

A Figura 3 apresenta a correlação existente entre a temperatura de isolamento do enrolamento e o torque do motor. Dentro do processo de operação de um motor de indução trifásico, o torque pode sofrer variações de acordo com a carga aplicada na ponta do seu eixo. Com o torque variando de 0 a 200%, a temperatura de isolamento do enrolamento não ultrapassou o valor de 70°C. Acima de 200% há maior dispersão dos valores de temperatura, que vão se concentrando em valores mais altos com o aumento do torque.

Sobrecargas na ponta do eixo do motor promovem o aumento do torque e, conseqüentemente, da temperatura do isolamento do enrolamento. O torque de até 200% deve ser mantido nesse nível para manter a temperatura do isolamento abaixo do limite da sua classe térmica.

**Figura 4** – Corrente e a temperatura de isolamento do enrolamento



Fonte: Autores, 2024

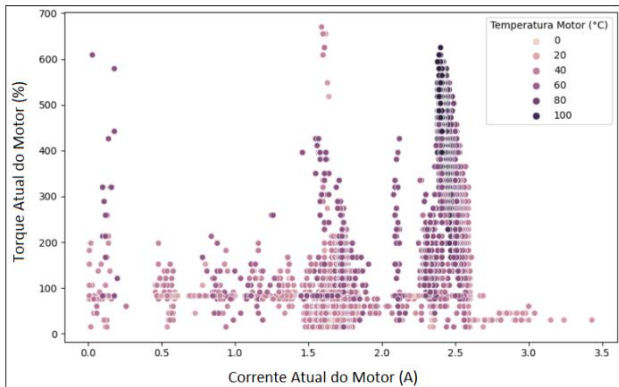
A Figura 4 apresenta a correlação existente entre a temperatura de isolamento do enrolamento e a corrente do motor. A corrente nominal do motor utilizado neste estudo é de 2,3A e, em determinadas condições de operação, o valor da corrente atingiu picos de 3,5A, mas sem impacto na temperatura de isolamento do enrolamento, pois a corrente não se manteve nesse valor. Em uma determinada condição de operação, o valor da corrente se manteve em 2,5A, levando a temperatura de isolamento do enrolamento para 115°C. Com valores de corrente elétrica de até 2,3A, a temperatura de isolamento do enrolamento não ultrapassou 76°C.

A corrente elétrica do motor sofre alterações de acordo com a carga aplicada na extremidade de seu eixo. A aplicação de cargas maiores que a capacidade nominal do motor exige mais torque, o que resulta em um aumento na corrente elétrica. Conexões elétricas ruins, defeitos nos rolamentos mecânicos e desbalanceamento da rede de alimentação, entre outros fatores, podem promover um aumento na corrente elétrica do motor e, conseqüentemente, na temperatura de isolamento do enrolamento.

A Figura 5 apresenta uma análise multivariada da corrente elétrica do motor, de seu torque e da temperatura de isolamento do enrolamento.



**Figura 5** – Relação entre corrente elétrica e torque do motor



Fonte: Autores, 2024

Toda a faixa de operação do motor de indução trifásico está apresentada nesta análise multivariada, variação de velocidade, variação de carga na ponta do eixo do motor, rampa de aceleração e desaceleração, e tempo de funcionamento no sentido horário e no sentido anti-horário. Os parâmetros que mais impactaram na temperatura de isolamento do enrolamento foram o torque atual e a corrente elétrica no motor.

Com o torque do motor abaixo dos 200%, a corrente elétrica e a temperatura do isolamento não ultrapassaram os valores limites. Quando o torque do motor está entre 200% e 400%, a temperatura sofreu um leve acréscimo. Para torques superiores a 500%, a temperatura atingiu valores superiores a 100°C, enquanto a corrente elétrica permaneceu na faixa de 2,5A.

## 5 CRIAÇÃO DO MODELO DE MACHINE LEARNING

Após todo o processo de verificação, análise e visualização dos dados, foi iniciada a construção do modelo de *Machine Learning* destinado a prever a temperatura de isolamento do enrolamento do motor. Este modelo foi desenvolvido utilizando a linguagem de programação *Python* e a biblioteca *Scikit-learn* dentro da *IDE Visual Studio Code*. Como o objetivo é prever a temperatura de isolamento do enrolamento, que é um número contínuo, foi empregado um processo de regressão. A primeira etapa na construção deste modelo foi definir o parâmetro dependente e os parâmetros independentes. A temperatura de isolamento do enrolamento do motor será o parâmetro dependente do modelo criado, enquanto o tempo horário, tempo anti-horário, velocidade, rampa de aceleração, rampa de desaceleração, frequência atual do motor, torque atual do motor e horímetro serão os parâmetros independentes.

Após a definição dos parâmetros, o modelo passou por um processo de validação com objetivo

de avaliar sua performance antes de ser aplicado a dados desconhecidos. O método utilizado para realizar essa validação foi o *hold-out validation*. O *dataset* foi dividido em dados de treino e dados de teste. Essa divisão visa utilizar uma parte do *dataset* para treinar o modelo criado e outra parte para testá-lo após o treinamento, verificando assim o seu desempenho quando for exposto a novos dados de entrada. Para os dados de treino, foram alocados 80% do *dataset*, enquanto os 20% restantes foram reservados para o teste.

Para modelos de regressão, consideramos as seguintes possibilidades: *Linear Regression*, *Ridge Regression*, *Lasso Regression*, redes neurais e árvores de decisão, com técnicas de *ensemble* em três possibilidades: *Bagging (Bagging Regressor)*, *Boosting (Boosting Regressor)* e *Stacking (Stacking Regressor)*, com objetivo de aumentar a robustez no tratamento de outliers.

O modelo *MLPRegressor (Multi-layer Perceptron Regressor)*, uma implementação das redes neurais artificiais, teve os seus parâmetros otimizados utilizando o *RandomizedSearchCV*. Esta abordagem permite explorar uma ampla gama de combinações de hiperparâmetros de forma eficiente. Os hiperparâmetros ajustados incluíram o número de camadas ocultas, o número de neurônios em cada camada, funções ativação, otimizadores, taxa de aprendizado, tamanho do lote e o parâmetro de regularização.

Os modelos de *ensemble Bagging Regressor*, *Boosting Regressor* e *Stacking Regressor* tiveram seus parâmetros otimizados utilizando a técnica de *RandomizedSearchCV*. Essa abordagem de otimização é essencial para explorar o espaço de hiperparâmetros de forma eficiente, permitindo que amostras aleatórias sejam testadas. Isso possibilita encontrar combinações de parâmetros que maximizem o desempenho dos modelos de *ensemble*.

No *Bagging Regressor*, a otimização ocorreu tanto para os parâmetros do modelo base, que foi o *DecisionTreeRegressor*, quanto para o número de estimadores, buscando reduzir a variância e melhorar a robustez das previsões. Os parâmetros selecionados para otimização foram: `'n_estimators'`, `'max_samples'`, `'max_features'`, `'bootstrap'` e `'bootstrap_features'`.

Para o *Boosting Regressor*, essa técnica permitiu ajustar hiperparâmetros críticos, como a taxa de aprendizado e o número de estimadores, elementos-chave para reduzir o erro de viés e aumentar a precisão do modelo ao longo das iterações sequenciais. Os parâmetros otimizados foram: `'n_estimators'`, `'learning_rate'`, `'max_depth'`, `'min_samples_split'`, `'min_samples_leaf'` e `'subsample'`.

Já no *Stacking Regressor*, a otimização desempenhou um papel fundamental na escolha dos melhores modelos base e na otimização do meta-modelo, assegurando que as previsões

combinadas maximizassem o desempenho final. Os modelos base utilizados foram: *RandomForestRegressor*, *SVR* e *DecisionTreeRegressor*. Os parâmetros de otimização para esses modelos foram: 'rf\_n\_estimators', 'rf\_max\_depth', 'svr\_C', 'svr\_epsilon' e 'dt\_max\_depth':

## 6 RESULTADOS

Após a construção e treinamento de todos os modelos, aplicaram-se métricas estatísticas para avaliar a precisão deles, medindo os erros entre os valores previstos e os valores reais com a utilização dos dados de teste. As métricas utilizadas foram:

- *Mean Absolute Error (MAE)*
- *Mean Squared Error (MSE)*
- *Root Mean Squared Error (RMSE)*

A métrica *Mean Absolute Error (MAE)* é a média do valor absoluto do erro de predição. A métrica *Mean Squared Error (MSE)* é a média do quadrado dos erros de predição. A métrica *Root Mean Squared Error (RMSE)* é a diferença entre o valor que foi predito pelo modelo e o valor real que foi observado. O Quadro 2 apresenta os resultados de cada uma dessas métricas para os modelos construídos.

Quadro 2 – Resultados métricas de avaliação

Modelo	Métricas		
	MAE	MSE	RMSE
Linear Regression	3,21	22,48	5,24
Lasso Regression	3,78	33,57	5,79
Ridge Regression	3,21	27,48	5,24
Redes Neurais	1,56	15,34	3,91
Bagging Regressor	0,90	4,57	2,13
Boosting Regressor	0,94	4,65	2,15
Stacking Regressor	0,94	4,70	2,16

Fonte: Autores, 2024

Com base nos dados apresentados no Quadro 2, o modelo *Bagging Regressor* teve o melhor desempenho em relação as métricas MAE, MSE e RMSE. Isso indica que o modelo *Bagging Regressor* teve, em média, os menores erros absolutos, os menores erros quadrados médios e a menor raiz quadrada média dos erros em comparação com os outros modelos listados no Quadro 2. Portanto, é razoável concluir que o modelo *Bagging Regressor* foi o mais eficaz entre os modelos avaliados com base nessas métricas específicas.

A avaliação da qualidade dos modelos ficou por conta do coeficiente de determinação ( $R^2$

*score*), que fornece uma indicação de quão bem as previsões dos modelos se ajustam aos dados reais. Ela indica a proporção da variação no parâmetro dependente (resposta) que é explicada pelo modelo em relação à variação total dos parâmetros dependentes. O Quadro 3 apresenta os resultados do coeficiente de determinação ( $R^2$  *score*) para cada um dos modelos de *Machine Learning*.

Quadro 3 – Resultados métrica  $R^2$

Modelo	$R^2$ "Dados de Treino"	$R^2$ "Dados de Teste"
Linear Regression	88,05%	87,96%
Ridge Regression	85,28%	85,29%
Lasso Regression	88,05%	87,96%
Redes Neurais	93,28%	93,28%
Bagging Regressor	98,26%	97,99%
Boosting Regressor	98,17%	97,96%
Stacking Regressor	98,16%	97,96%

Fonte: Autores, 2024

O intervalo de previsão foi a ferramenta estatística utilizada na análise e avaliação dos modelos de *Machine Learning* com o objetivo de compreender a confiabilidade e a incerteza das predições realizadas por esses modelos. Esse intervalo fornece uma faixa de valores dentro da qual se espera que o valor real da temperatura de isolamento do enrolamento esteja, com uma determinada probabilidade. Para todos os modelos, foi utilizado um intervalo de previsão com um nível de confiança de 90% ( $\alpha = 0,1$ ). Isso significa que o intervalo cobre 90% das possíveis observações, ou seja, há uma probabilidade de 90% de que as futuras observações estejam dentro desse intervalo. O Quadro 4 apresenta os intervalos de previsão para cada um dos modelos de *Machine Learning*.

Quadro 4 – Intervalo de previsão

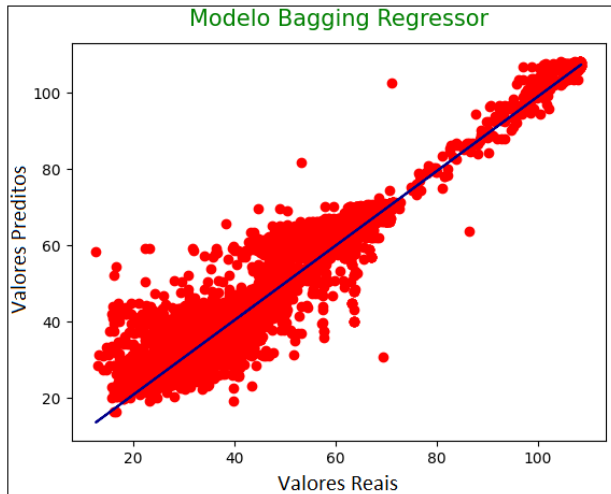
Modelo	Temp. Real	Temp. Predita	Intervalo de Previsão
Linear Regression	65°C	58,18°C	51,62°C a 64,73°C
Ridge Regression	65°C	57,52°C	47,72°C a 67,31°C
Lasso Regression	65°C	58,11°C	51,61°C a 64,62°C
Redes Neurais	65°C	62,32°C	61,12°C a 63,52°C
Bagging Regressor	65°C	66,17°C	65,53°C a 66,81°C
Boosting Regressor	65°C	66,06°C	64,57°C a 67,56
Stacking Regressor	65°C	66,10°C	63,17°C a 66,76

Fonte: Autores, 2024

Os resultados obtidos com o modelo *Bagging Regressor* mostram uma alta capacidade preditiva tanto nos dados de treino quanto nos dados de teste. Esses resultados descartam a possibilidade de *overfitting*, um problema comum no aprendizado de máquina em que o modelo se ajusta excessivamente aos dados de treino, aprendendo tanto os padrões reais quanto o ruído e as peculiaridades desses dados. Como resultado, o modelo apresenta um desempenho excelente nos dados de treino. O coeficiente de determinação ( $R^2$  *score*) de 98,26% nos dados de treino indica que o modelo se ajusta muito bem aos dados nos quais

foi treinado, e a precisão de 97,99% nos dados de teste sugere que o modelo generaliza bem para novos dados, mantendo praticamente o nível de desempenho. O intervalo de previsão garantido pelo modelo varia de 65,53°C a 66,81°C, assegurando uma estimativa precisa da temperatura de isolamento dos motores de indução trifásicos. O gráfico da Figura 6 apresenta a relação entre os valores reais e preditos para este modelo.

**Figura 6** – Valores Reais versus Valores Preditos  
Modelo Bagging Regressor



Fonte: Autores, 2024

Um segundo modelo de regressão linear foi desenvolvido com o objetivo de prever o tempo necessário para que a temperatura do isolamento atinja o limite previsto na classe térmica do motor. Para o motor em estudo, a classe de isolamento é B, com um limite de 130°C.

Para este segundo modelo, tempo de operação do motor será o parâmetro dependente, enquanto o tempo horário, tempo anti-horário, velocidade, rampa de aceleração, rampa de desaceleração, frequência atual do motor, torque atual do motor e temperatura de isolamento do enrolamento serão os parâmetros independentes.

Após esta definição, o *dataset* foi dividido em dados de treino e dados de teste. Para os dados de treino, foram alocados 80% do *dataset*, enquanto os 20% restantes foram reservados para o teste. Assim, se uma previsão do modelo *Bagging Regressor* indicar que a temperatura de isolamento do enrolamento alcançará o limite da classe térmica do motor, o tempo para essa ocorrência também será previsto.

Para uma melhor visualização dos dados coletados e do processo de previsão da temperatura de isolamento do enrolamento, desenvolvemos uma segunda interface gráfica utilizando a linguagem de programação Python e *Tkinter*. Nesta interface, além de visualizar a previsão da temperatura de isolamento do enrolamento, é possível também acompanhar o tempo necessário para que esse valor

atinja o limite da classe térmica do motor. A Figura 7 apresenta essa interface.

**Figura 7** – Interface gráfica modelo de previsão

Fonte: Autores, 2024

## 7 CONCLUSÃO

Como um dos pilares da Indústria 4.0, os algoritmos de *Machine Learning* estão se consolidando como uma nova estratégia dentro das rotinas de manutenção industrial. Previsões bem-sucedidas feitas por esses algoritmos promovem uma antecipação nos processos de manutenção, garantindo que falhas e defeitos não venham a interromper a operação de máquinas e equipamentos industriais.

O presente estudo mostrou as técnicas de *Machine Learning* aplicadas na previsão da temperatura de isolamento do enrolamento de um motor de indução trifásico, com o objetivo de manter essa temperatura abaixo do limite da classe térmica do motor. Com o modelo de *Machine Learning* recebendo dados de operação, sistema de partida e processo no qual o motor está inserido, ele deverá prever a temperatura de isolamento do enrolamento para um processo de antecipação em rotinas de manutenção. Essa antecipação deve garantir que a temperatura de isolamento do enrolamento não atinja os limites estabelecidos pela classe térmica de isolamento do motor.

Durante o processo de construção do modelo de *Machine Learning*, as seguintes possibilidades foram consideradas: *Linear Regression*, *Ridge Regression*, *Lasso Regression*, redes neurais e árvores de decisão com técnicas de



ensemble em três possibilidades: *Bagging (Bagging Regression)*, *Boosting (Boosting Regressor)* e *Stacking (Stacking Regressor)*. O modelo *Bagging Regression* foi selecionado considerando os bons resultados obtidos para as métricas de avaliação MAE, MSE, RMSE,  $R^2$  e intervalo de previsão. Para os dados de treino, o coeficiente de determinação ( $R^2$ ) foi de 98%, enquanto, para os dados de teste, foi de 97%. Para uma temperatura real de 65°C, a predição foi de 66,2°C, com intervalo de previsão de 64,2°C a 67,2°C. A convergência entre a tecnologia de automação (TA) e a tecnologia da informação (TI) foi o ponto-chave para o desenvolvimento deste estudo.

## REFERÊNCIAS

- [1] PROVOST, F; FAWCETT, T. **Data science and its relationship to big data and data-driven decision making**. Big data, v. 1, n. 1, p. 51-59, 2013.
- [2] CARVALHO, T.P.; Soares, F.A.A.M.N.; Vita, R.; FRANCISCO, R.P.; BASTO, J.P.; ALCALÁ, S.G.S. **A systematic literature review of machine learning methods applied to predictive maintenance**. Comput. Ind. Eng. 2019, 137, 106024.
- [3] MULLER, C. Andreas; GUIDO, Sarah. **Introduction to Machine Learning with Python**. Estados Unidos O'REILLY 2016.
- [4] LEE, W.J.; WU, H.; YUN, H.; KIM, H.; JUN, M.B.G.; SUTHERLAND J.W. **Predictive Maintenance of Machine Tool Systems Using Artificial Intelligence Techniques Applied to Machine Condition Data**. In Proceedings of the 26th CIRP Conference on Life Cycle Engineering (LCE), West Lafayette, IN, USA, 7–9 May 2019; Volume 80, pp. 506–511.
- [5] CHEN, C.; LIU, Y.; WANG, S.; SUN, X.; DI CAIRANO-GILFEDDER, C.; TITMUS, S.; SYNTETOS, A.A. **Predictive maintenance using cox proportional hazard deep learning**. Adv. Eng. Inform. 2020, 44, 101054.
- [6] THEISSLER, A.; PÉREZ-VALÁZQUEZ, J.; KETTELGERDES, M.; ELGER, G. **Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry**. Reliab. Eng. Syst. Saf. 2021, 215, 107864.
- [7] Czerwinski, D.; Geça, J.; Kolano, K. **Machine Learning for Sensorless Temperature Estimation of a BLDC Motor. Sensors 2021**
- [8] Nogay, H.S. **Prediction of Internal Temperature in Stator Winding of Three-Phase Induction Motors with Ann**. Eur. Trans. Electr. Power 2011, 21, 120–128.
- [9] W. Kirchgässner, O. Wallscheid and J. Böcker, **Estimating Electric Motor Temperatures With Deep Residual Machine Learning**, in IEEE Transactions on Power Electronics, vol. 36, no. 7, pp. 7480-7488, July 2021.
- [10] FERRAZ, Fabio; APARECIDA, Roseli; HSIEH, Sheng-Jen. **Machine Learning for the Detection and Diagnosis of Anomalies in Applications Driven by Electric Motors**, v. 23, n. 24, p. 9725, 2023.
- [11] WEG. **Guia de Especificações de Motores Elétricos**. 2022. Disponível em: <https://static.weg.net/medias/downloadcenter/h32/hc5/WEG-motores-eletricos-guia-de-especificacao-50032749-brochure-portuguese-web.pdf>
- [12] PINTO, W. P. **Uso da Metodologia de Dados Faltantes em Séries Temporais com Aplicações a dados de Concentração (PM10) Observados na Região da Grande Vitória**. Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Ambiental do Centro Tecnológico da Universidade Federal do Espírito Santo, 2013.
- [13] ASSUNÇÃO, F. **Estratégias para tratamento de variáveis com dados faltantes durante o desenvolvimento de métodos preditivos**. Dissertação de Mestrado da Universidade de São Paulo, São Paulo, 2012.
- [14] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 17094: Máquinas Elétricas Girantes**. Rio de Janeiro, 2018.
- [15] **Scikit-learn Machine Learning with Python**. 2022. Disponível em: <https://scikit-learn.org/stable/>
- [16] WELT, R.; ESTLER, M.; LUCKE, D. **A Method for Implementation of Machine Learning Solutions for Predictive Maintenance in Small and Medium-Sized Enterprises**. In Proceedings of the 53rd CIRP Conference on Manufacturing Systems, Chicago, IL, USA, 1–3 July 2020; Volume 93, pp. 909–914.
- [17] WEG. **Manual do Inversor de Frequência**. 2009. Disponível em: <https://static.weg.net/medias/downloadcenter/h5b/h4b/WEG-CFW08-user-manual-0899.5241-en-es-pt-de-fr-ru-nl-sv.pdf>

[18] BARNARD, J.MENG, Xiao-Li. **Applications of multiple imputation in medical studies: from AIDS to NHAMES**. Statistical Methods in Medical Research, v. 8, n. 1, p. 17-36, 1999.

[19] HRUSCHKA JR, E. R.; HRUSCHKA, E. R.; EBECKEN, Nelson FF. Bayesian networks for imputation in classification problems. **Journal of Inteligente Information System**, v. 29, n 3, p. 231-252, 2007.