

MONITORAMENTO DA CONDIÇÃO TÉRMICA DE MOTORES DE INDUÇÃO TRIFÁSICOS USANDO SENSORIAMENTO DE TEMPERATURA NO ESTATOR E REDES NEURAIAS

Alisson Antonio dos Santos, Rayssa Milena Castro Correia e Renato Kazuo Miyamoto*

RESUMO

Os motores de indução trifásicos são amplamente utilizados na indústria moderna, sendo essenciais para a operação de sistemas produtivos. No entanto, falhas térmicas inesperadas nesses motores podem ocasionar prejuízos significativos. Este trabalho propõe o desenvolvimento de um estimador de temperatura baseado em Redes Neurais Artificiais (RNA), com o objetivo de viabilizar o monitoramento preditivo da temperatura em motores de indução trifásicos. Para isso, foi utilizado um sensor de baixo custo instalado diretamente nas bobinas do estator do motor, permitindo a coleta de dados térmicos sob diversas condições reais de operação. Os dados obtidos foram aplicados no treinamento de diferentes topologias de RNA. Os resultados demonstraram uma assertividade superior a 99% em determinadas configurações, evidenciando o potencial da abordagem proposta para a predição de falhas térmicas e para a implementação de estratégias de manutenção preditiva.

Palavras-chave: Motor de indução trifásico; Manutenção preditiva; Falhas térmicas; Redes neurais artificiais; Monitoramento de temperatura.

Thermal Condition Monitoring of Three-Phase Induction Motors Using Stator Temperature Sensing and Neural Networks

ABSTRACT

Three-phase induction motors are widely used in modern industry and are essential to the operation of production systems. However, unexpected thermal failures in these motors can result in significant losses. This work proposes the development of a temperature estimator based on Artificial Neural Networks (ANNs) to enable predictive temperature monitoring in three-phase induction motors. A low-cost sensor was installed directly on the motor stator windings to collect thermal data under various real operating conditions. The collected data were used to train different ANN topologies. The results showed assertiveness exceeding 99% in certain configurations, highlighting the potential of the proposed approach for thermal fault prediction and the implementation of predictive maintenance strategies.

Keywords: Three-phase induction motor; Predictive maintenance; Thermal faults; Artificial neural networks; Temperature monitoring.

* Autor correspondente (e-mail): renato.miyamoto@sistemafiep.org.br

1. INTRODUÇÃO

O motor de indução trifásico (MIT) é amplamente utilizado em diferentes áreas da indústria devido ao seu baixo custo de aquisição e manutenção, eficiência, facilidade de controle e robustez diante de diversos ambientes e cargas mecânicas. Isso pode ser constatado pelo fato de que os motores elétricos são responsáveis por 43% a 46% do consumo de energia elétrica total produzida no mundo (Robles *et al.*, 2021; Prince; Hati, 2021).

Segundo o Grupo *ABB*, cerca de 45% da eletricidade consumida no mundo é utilizada no acionamento de motores industriais e, aproximadamente 300 milhões de motores elétricos industriais estão atualmente em operação. As indústrias são responsáveis pelo consumo de 35% da energia elétrica produzida no Brasil (segundo a EPE (Empresa de Pesquisa Energética). Adicionalmente, de acordo com Weg (2021), estima-se que no Brasil existam mais de 20 milhões de motores de indução trifásico (MIT) em operação. A mesma pesquisa indica que esses motores consomem aproximadamente 140 GW/h por ano, o que corresponde a 23,25% do consumo total de energia elétrica do Brasil.

Com a competição entre empresas e a constante busca por linhas de produção mais eficientes e menos dispendiosas, cria-se a demanda pelo monitoramento contínuo da saúde dos motores. Fazendo uso de tal monitoramento é possível detectar de forma precoce falhas que possam vir a ocorrer no motor, permitindo assim medidas preventivas, com o intuito de aumentar a vida útil da máquina, e diminuir o tempo que a linha de produção precisaria ficar interrompida. Este fato pode contribuir para a redução dos custos da indústria, tornando-a mais competitiva perante o mercado (Choudhary *et al.*, 2019).

Dentre as diversas condições que podem comprometer a integridade operacional dos motores de indução trifásicos (MIT) destaca-se a sobrecarga térmica, que pode ser proveniente de alguns fatores, a saber: i) causada pela deterioração de componentes do motor; ii) causada pela sobrecarga mecânica no eixo do motor; e iii) causada pelo desequilíbrio de tensão de alimentação do motor de indução.

A sobrecarga térmica pode ser causada pela deterioração nos diversos componentes do motor de indução trifásico (MIT), entre eles: os condutores do estator e do rotor, o isolamento, o núcleo e os rolamentos, destacando-se como uma das principais causadoras de falhas nos motores (Bonnett, 1992).

A sobrecarga mecânica também representa um fator crítico para a vida útil dos motores de indução trifásicos (MIT). Esse tipo de sobrecarga ocorre quando o motor é submetido a esforços superiores à sua capacidade nominal, seja por variações na carga acionada, desalinhamento de componentes, acoplamentos inadequados ou bloqueio mecânico do eixo. Esse estresse excessivo pode resultar em aquecimento anômalo, desgaste prematuro dos rolamentos, aumento do consumo de energia e redução da eficiência do motor. Com o tempo, a sobrecarga mecânica pode levar à falha prematura do sistema, tornando indispensável a adoção de estratégias de monitoramento e manutenção preditiva para evitar paradas inesperadas e custos elevados de reparo (Bonnett, 1992).

Já quando o motor opera em condição de desequilíbrio de tensão, o aquecimento excessivo intensifica o estresse térmico nos componentes internos, acelerando o processo de degradação dos materiais isolantes e dos rolamentos. Esse aumento de temperatura impacta diretamente a eficiência do motor, elevando as perdas energéticas e contribuindo para um desgaste prematuro dos componentes. Além disso, apresenta simultaneamente características girante e pulsante em seu torque eletromagnético.

Segundo Oliveira (2011), devem ser consideradas as componentes de sequência inversa da tensão associando um campo girante de mesma frequência com sentido de rotação inverso àquele da sequência direta. Esse fenômeno, além de sobreaquecimento, gera um aumento significativo da vibração do eixo, diminuindo em até quatro anos e meio de serviço na vida útil do MIT trabalhando com um fator de dois por cento de desequilíbrio.

Neste cenário, a termografia é uma das técnicas geralmente utilizadas para o monitoramento térmico de MITs, por ser uma ferramenta não invasiva. A partir de uma câmera termográfica é possível a visualização do comportamento térmico da

superfície do motor, o que permite a detecção de uma possível anomalia térmica (Pinheiro, Romário de Mesquita et al. (2012); Picazo-Rodenas *et al.* (2012). Entretanto, a medição através de câmeras termográficas possui seus contrapontos. De acordo com Lagüela *et al.* (2011), a diferença entre as aferições de câmeras de marcas diferentes é discutida.

Na pesquisa de Lopes *et al.* (2013) utilizou-se um sensor de temperatura para monitorar o aquecimento externo na carcaça do MIT. Ainda, aplicaram-se redes neurais artificiais para estimar o valor da temperatura em momentos futuros, aplicando situações que submetam o MIT a temperaturas que ultrapassam o seu limite térmico, possibilitando a detecção da elevação de temperatura da carcaça da máquina. Foram elaboradas duas matrizes de 13 linhas e 50 colunas, a primeira contendo subamostras de 1000 dados e a segunda de 500 dados. Os autores coletaram os dados da temperatura da carcaça do MIT.

Assim, o uso de sistemas inteligentes vem se destacando na identificação e no monitoramento preditivo de falhas em máquinas elétricas. De forma a tratar com robustez as incertezas no processamento de dados, pode-se utilizar as Redes Neurais Artificiais (RNA) (Suetake, 2012). Com as novas técnicas da indústria 4.0, a análise em tempo real dos parâmetros de uma máquina está tornando-se corriqueira devido a crescente capacidade de processamento e armazenamento de dados, além da maior conectividade dentro das indústrias (Qi; Tao, 2018).

O monitoramento térmico de MIT possui diversas abordagens e estudos que comprovam sua eficiência em detectar a falha precoce, permitindo corrigir os problemas de maneira planejada e antecipada. Entretanto, observa-se uma carência em obter dados dos motores sob diversas condições de carga e tensão de operação. Com a dependência de motores de indução trifásicos nas aplicações industriais, a manutenção térmica preditiva permite estender a vida útil da máquina e o processo produtivo, reduzindo o tempo de parada não programada que poderiam levar a perdas financeiras.

Diante desse contexto, a principal motivação deste trabalho consiste na aplicação de redes neurais no monitoramento preditivo da temperatura em um motor

de indução trifásico. Para isso, foram coletados dados de temperatura do enrolamento do estator de um MIT sob diversas condições operacionais, incluindo situações de carga e sobrecarga mecânica, rolamentos em estado saudável e deteriorado, além de variações de tensão. A aquisição dos dados foi realizada por meio de sensores de baixo custo e microcontroladores, viabilizando um sistema acessível e eficiente. Esses dados são utilizados para o treinamento de uma rede neural, com o objetivo de desenvolver um estimador de temperatura capaz de prever variações térmicas e indicar possíveis falhas, contribuindo para a manutenção preditiva e a maior confiabilidade dos motores elétricos.

Assim, o presente estudo justifica-se pela necessidade de desenvolver um modelo eficiente de monitoramento da temperatura desses motores para prever variações térmicas em diferentes condições de operação, permitindo a detecção precoce de anomalias. Dessa forma, o trabalho contribuirá para a otimização de estratégias de manutenção preditiva, reduzindo paradas não programadas e aumentando a confiabilidade dos sistemas industriais. Uma breve introdução sobre as contribuições e as características do tema proposto nesse trabalho foi apresentada. A sequência deste trabalho está organizada em 4 seções, a saber: fundamentação teórica, metodologia, apresentação de resultados e conclusão.


2 FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta o embasamento teórico sobre os motores de indução trifásicos (MIT), e sobre os sistemas que podem ser aplicados para uma detecção de falhas térmicas nessas máquinas elétricas. Ainda, são abordados os aspectos referentes aos sensores utilizados para leitura dos dados, ao *hardware* e aos *softwares* utilizados para efetuar a aquisição dos dados desse trabalho.

2.1 O motor de indução trifásico e seu modelo térmico

Segundo Barbara (2023), as máquinas de indução trifásicas possuem entre as suas partes construtivas os enrolamentos do estator, o rotor, o estator, os rolamentos, a carcaça e os terminais de ligação. O rotor desta máquina pode ser do tipo gaiola de esquilo, onde o enrolamento dele é constituído por barras conectadas entre si. A Figura 1 mostra as partes de uma máquina de indução trifásica com rotor em gaiola de esquilo. Destacam-se as partes construtivas do motor, tais como o estator, o rotor, os enrolamentos do estator e os rolamentos. Quando há desgaste ou falha nos rolamentos, ocorre aumento da excentricidade do rotor, o que pode gerar aquecimento anômalo no estator devido ao atrito irregular e às vibrações. Esse aquecimento excessivo compromete o isolamento das bobinas e acelera a degradação dos materiais, reduzindo a vida útil do motor e aumentando o risco de falhas térmicas.

Figura 1 - Partes de uma máquina de indução trifásica assíncrona.



Fonte: Weg (2021).

Segundo Toliyat (2004), as condições que podem submeter motores de indução trifásicos (MIT) a temperaturas acima de seu limite térmico envolvem três categorias principais: sobrecarga térmica transiente ou de partida, sobrecarga durante o funcionamento e condições anormais de resfriamento. A primeira categoria inclui situações como sobrecargas transitórias, partidas frequentes e rotor bloqueado, além de curto-circuito com falta à terra. A segunda categoria refere-se a sobrecargas contínuas e ao desequilíbrio das tensões de alimentação. Por fim, as condições anormais de resfriamento abrangem a operação em ambientes com temperatura elevada e a redução da capacidade de arrefecimento do motor.

A Figura 2 apresenta as principais falhas que ocorrem em motores de indução trifásicos, destacando a predominância de falhas localizadas nas bobinas do estator.

Figura 2 - Principais falhas em motores de indução trifásico.




Fonte: WEG (2021).

De acordo com a ilustração, aproximadamente 94% das falhas estão concentradas nessa região, evidenciando sua vulnerabilidade diante das condições

operacionais adversas. Essa concentração de falhas pode estar relacionada à exposição direta das bobinas ao aquecimento excessivo, vibrações mecânicas e degradação do isolamento. A análise da figura reforça a relevância do monitoramento térmico focado nos enrolamentos do estator, uma vez que o comprometimento dessa área pode levar à perda total do motor.

Os motores de indução possuem características térmicas, mecânicas e elétricas que devem ser respeitadas para seu funcionamento adequado e longevidade. Referente as características térmicas o motor de indução é dividido em categorias sendo elas A,E,B,F,H, conforme ilustra a Figura 3.

Figura 3 - Gráfico da relação entre vida útil e temperatura de funcionamento.



Fonte: Chapman (2013).

Na referida classificação, a classe A permite uma elevação de temperatura de até 60 C°, enquanto a categoria H permite uma elevação de até 125 C° (CHAPMAN, 2013). Como pode ser observado no gráfico apresentado na Figura 3, operar o motor acima da temperatura nominal da respectiva classe de isolamento gera uma perda significativa em vida útil da máquina.

Segundo Avolio (1992), o modelo térmico do motor de indução trifásico baseia-se na analogia existente entre o comportamento de um circuito elétrico tipo RC alimentado por uma fonte de corrente e o comportamento térmico da máquina. Embora ela seja composta por partes que se diferenciam fisicamente, quando feita a análise do comportamento térmico de somente algumas dessas partes, pode ser utilizada a teoria do aquecimento de um corpo sólido ideal, ocasião em que o calor é dissipado uniformemente por toda sua superfície, conforme a seguinte expressão:

$$Q \cdot dt - A \cdot \lambda \cdot \theta \cdot dt = m \cdot c \cdot d\theta \quad (1)$$

onde:

Q é a energia térmica por unidade de tempo (W);

A é a área da superfície do corpo;

λ é o coeficiente de transmissão de calor do corpo ($\frac{W}{^{\circ}C \cdot m^2}$);

θ é a temperatura do corpo ($^{\circ}C$);

m é a massa do corpo (kg);

c é o calor específico do material que constitui o corpo ($\frac{W \cdot s}{^{\circ}C \cdot Kg}$).

Assim, através da equação (1), observa-se que a obtenção da temperatura na máquina pelo uso do modelo matemático exige conhecer os parâmetros térmicos do motor em análise. Estes parâmetros variam conforme o projeto da máquina. Desta maneira, faz-se necessária a utilização de um procedimento de baixo custo para avaliar a temperatura no motor, independentemente dos parâmetros térmicos da máquina.

2.2. Sobrecargas Térmicas em Motores de Indução

A sobrecarga térmica pode comprometer a integridade operacional dos motores de indução trifásicos (MIT) e pode ser causada por:

- i) deterioração de componentes do motor;
- ii) pela sobrecarga mecânica no eixo do motor;

iii) pelo desequilíbrio de tensão de alimentação do motor de indução.

2.2.1 Deterioração de Componentes do Motor

Os rolamentos consistem nos componentes-chave do sistema de transmissão mecânica do motor e são empregados para reduzir o efeito do atrito no rotor. Devido às forças radiais, o desgaste superficial do rolamento entre as pistas e esferas é frequentemente negligenciado devida à lenta degradação. O acúmulo dos desgastes leva a uma crescente folga radial, provocando a excentricidade dinâmica do rotor, que por sua vez deteriora as condições de trabalho da máquina (Liu, Y. *et al.*, 2022; Machado, T. H.; Alves; Cavalca, 2019).

Nesse contexto, os desgastes abrasivos ocorrem naturalmente com o uso contínuo dos rolamentos. No entanto, efeitos secundários influenciam os desgastes, como a intrusão de partículas estranhas nos rolamentos (poeiras, grãos abrasivos e limalhas) e as falhas na lubrificação (falta, excesso ou lubrificante inadequado). Como consequência, o atrito no rolamento aumenta e pode resultar em problemas de pontuação, indentação e abrasão da peça. Desse modo, o desempenho do rolamento devido aos desgastes diminuirá com o passar do tempo, aumentando a excentricidade do rotor no estator. Nesse caso, problemas de aquecimento, oscilações na velocidade e torque instantâneos do motor serão acentuados (Kumar N.; Vinothraj C.; Isha T. B., 2018; Liu, Z.; Zhang, 2020).

2.2.2 Sobrecarga mecânica no eixo do motor

A sobrecarga ocorre devido ao aumento do carregamento mecânico do motor acima do seu valor nominal. Como a carga no eixo torna-se excessiva, o rotor perde rotação e pode ficar bloqueado; situação equivalente a um curto-circuito. Embora a máquina de indução seja projetada para suportar sobrecargas por certos períodos, a persistência desta condição faz com que a corrente se eleve acima do valor nominal. Nesse caso, há um aumento considerável do estresse térmico sobre o motor,

reduzindo sua vida útil e causando danos na isolação do enrolamento do estator. Os efeitos da sobrecarga são minimizados normalmente por relés de sobrecorrente ou fusíveis de proteção conectados na alimentação da máquina (Gonzalezcordoba *et al.*, 2017; Karmakar *et al.*, 2016).

2.2.3 Desequilíbrio de tensão de alimentação do motor

Os desequilíbrios de tensão provocam a circulação de correntes de sequência negativa nos motores de indução, elevando as perdas ôhmicas nos enrolamentos da máquina, produzindo oscilações no torque, potência e velocidade. Nesse caso, o aumento da energia dissipada no cobre leva a um acréscimo da temperatura das bobinas, acelerando a degradação do isolamento do estator. Para as máquinas do tipo gaiola de esquilo, a resistência de sequência negativa é da ordem de cinco vezes maior que a resistência de sequência positiva (Donolo; Bossio; De Angelo, 2011).

As técnicas de monitoramento para o diagnóstico de falhas em motores de indução precisam ser aperfeiçoadas para detectar, o mais rápido possível, os diferentes tipos de falhas que podem ocorrer no motor. As redes neurais artificiais possuem características que podem detectar essas falhas dependendo apenas de sua programação. É necessário selecionar apropriadamente as entradas e saídas da rede, a estrutura e os dados convenientes para o seu treinamento. Desta forma, na sequência, são descritos os aspectos relacionados a lógica e ao princípio de funcionamento das Redes Neurais Artificiais.

2.3 Redes neurais artificiais

A Rede Neural Artificial (RNA) é um sistema criado para emular o modo como o cérebro humano aborda uma tarefa específica. Assim, pode ser definida como um conjunto de ferramentas computacionais inspiradas no sistema nervoso de seres vivos. As RNAs consistem em neurônios artificiais conectados por sinapses artificiais, representadas por vetores ou matrizes de pesos sinápticos (Lopes *et al.*, 2013).

Essas redes são conjuntas de unidades de processamento que têm a capacidade de adquirir e reter conhecimento com base em informações. Entre suas principais características estão a adaptação por experiência, a habilidade de aprendizado, a capacidade de generalização, a organização de dados, a tolerância a falhas, o armazenamento distribuído e a facilidade de prototipagem (Silva; Spatti; Flauzino, 2010).

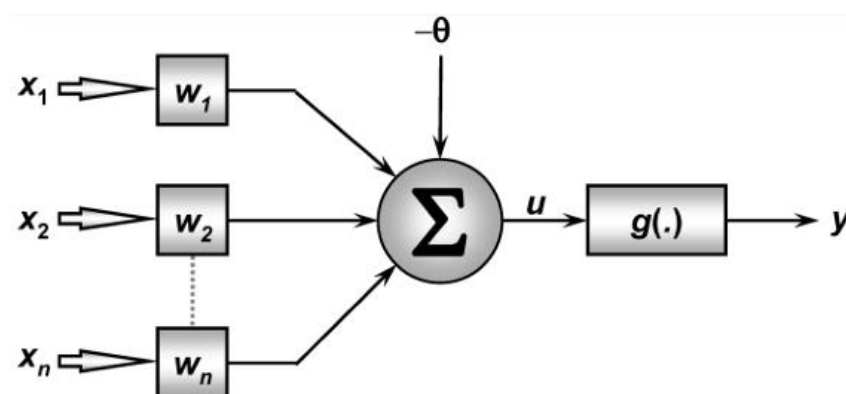
Com isso, é possível desenvolver modelos capazes de prever o comportamento de um processo específico e tomar ações para controlá-lo de maneira adequada. Essas redes oferecem a capacidade não apenas de aprender com dados, mas também de aplicar esse conhecimento para previsões e controle eficaz (Haykin, 2001). Com o significativo avanço tecnológico, os microprocessadores viram seu poder computacional ampliado, o que impulsionou o uso das redes neurais como uma alternativa inovadora para resolver problemas complexos em diferentes campos, entre eles a estimativa de temperatura em motores elétricos.

O processamento de informações no cérebro humano é governado por elementos processadores biológicos que operam em paralelo. A unidade fundamental do sistema nervoso cerebral é o neurônio, cuja função principal consiste na condução de impulsos, ou seja, estímulos elétricos (Haykin, 2001). Os neurônios biológicos são responsáveis por todo o processamento gerenciado pelo cérebro humano. Essas células nervosas formam a base do sistema nervoso, facilitando a comunicação, a transmissão de informações e a coordenação das funções cerebrais. Apesar disso, é relevante mencionar que não há contato físico direto entre eles. A comunicação entre neurônios acontece por meio de estruturas chamadas sinapses, imersas em substâncias neurotransmissoras, que viabilizam a transferência de informações de um neurônio para outro (Silva; Spatti; Flauzino, 2010).

No contexto do modelo biológico, as influências transmitidas pelas conexões sinápticas são representadas em neurônios artificiais por conjuntos de pesos sinápticos (denominados como $W_1, W_2 \dots W_n$). Analogamente, a relevância de cada entrada individual $X_1, X_2 \dots (X_n)$ para o neurônio é determinada ao multiplicá-la pelo peso sináptico correspondente (Silva; Spatti; Flauzino, 2010).

Isso implica que todas as informações provenientes do exterior e recebidas pelo neurônio são consideradas, resultando na saída do neurônio artificial, que é o produto dessas ponderações das entradas, como ilustrado na Figura 4.

Figura 4 - Neurônio Artificial



Fonte: Silva *et al.*, (2010).

Segundo Silva *et al.* (2010), o funcionamento de um neurônio descreve-se pela seguinte equação matemática:

$$Y = g \left(\sum_{i=1}^n W_i \cdot X_i + b \right) \quad (2)$$

onde:

n é o número de entradas do neurônio;

W_i é o peso associado com a i -ésima entrada;

b é o limiar associado ao neurônio;

X_i é a i -ésima entrada do neurônio;

$g(.)$ é a função de ativação do neurônio;


Y é a saída do neurônio.

Diversas topologias de RNA são obtidas com base na estrutura do neurônio artificial, podendo ser classificadas como redes de camada única ou redes multicamadas. Dessa forma, um neurônio artificial caracteriza-se por ser a unidade básica de processamento em uma rede neural. O *perceptron*, por sua vez, é um tipo

específico de rede neural composta por um único neurônio ou camada de neurônios, capaz de realizar apenas classificações lineares simples. No entanto, quando múltiplas camadas de neurônios são empilhadas em uma rede, formando o que é conhecido como uma rede neural *Perceptron* de Múltiplas Camadas (PMC), ela se torna capaz de lidar com tarefas mais complexas e não lineares (Lopes et al., 2013).

A transformação de um neurônio artificial em uma PMC envolve a criação de várias camadas de neurônios interconectados. Cada camada, exceto a de entrada, contém neurônios que recebem sinais de todos os neurônios da camada anterior. Esses neurônios em camadas intermediárias (também chamadas de camadas ocultas) processam as informações recebidas, aplicam pesos e funções de ativação, e passam as saídas para a próxima camada, conforme ilustra a Figura 5 (Silva; Spatti; Flauzino, 2010).

Figura 5 – Treinamento de uma PMC



Fonte: Silva et al. (2010).

A adição de múltiplas camadas permite que a rede aprenda representações mais complexas dos dados, capturando relações não lineares entre as características. Isso é alcançado por meio de um processo chamado treinamento, no qual a rede neural ajusta os pesos das conexões entre os neurônios para minimizar o erro entre as saídas previstas e os resultados reais durante a fase de treinamento (Haykin, 2001).

Um dos métodos de treinamento mais consolidados consiste no treinamento supervisionado *backpropagation* conhecido também como regra Delta generalizada, ele usa o gradiente descendente para atualizar os pesos, minimizando o erro entre a saída real e a desejada, o gradiente descendente é um algoritmo de otimização usado para encontrar o mínimo de uma função, ou seja, o ponto onde essa função tem o menor valor possível conforme a equação 3.

$$W_{\{ji\}}^{\{(L)\}(t+1)} = W_{\{ji\}}^{\{(L)\}(t)} + \eta \cdot \delta_j^{\{(L)\}} \cdot Y_i^{\{(L-1)\}} \quad (3)$$

onde:

$W_{\{ji\}}^{\{(L)\}(t)}$ é o valor atual do peso entre o neurônio i da camada $L - 1$ e o neurônio j ;

η é a taxa de aprendizagem;

$\delta_j^{\{(L)\}}$ é o erro local do neurônio j da camada L ;

$Y_i^{\{(L-1)\}}$ é a saída do neurônio i da camada anterior;

$W_{\{ji\}}^{\{(L)\}(t+1)}$ é o novo valor do peso após a atualização.

Esse método é muito utilizado no treinamento de redes neurais e em outros algoritmos de aprendizado de máquina. Outro algoritmo de otimização é o gradiente descendente com momentum, O termo momentum foi introduzido para acelerar o aprendizado e evitar que o algoritmo fique preso em mínimos locais conforme a equação 4 (Silva; Spatti; Flauzino, 2010).

$$W_{\{ji\}}^{\{(L)\}(t+1)} = W_{\{ji\}}^{\{(L)\}(t)} + \alpha \cdot \left(W_{\{ji\}}^{\{(L)\}(t)} - W_{\{ji\}}^{\{(L)\}(t-1)} \right) + \eta \cdot \delta_j^{\{(L)\}} \cdot Y_i^{\{(L-1)\}} \quad (4)$$

onde α é definida como taxa de momentum.

O treinamento ocorre em duas etapas. A primeira etapa, conhecida como "propagação direta" (*forward*), inicia-se ao inserir os sinais x_1, x_2, \dots, x_n de uma amostra do conjunto de treinamento nas entradas da rede. Esses sinais são então propagados através das várias camadas da rede, culminando na geração das respectivas saídas. Em seguida, as respostas produzidas pelas saídas da rede são

confrontadas com as respostas desejadas disponíveis, dado que se trata de um processo de aprendizado supervisionado (Silva; Spatti; Flauzino, 2010).

Se considerarmos uma rede *Perceptron* Multicamadas (PMC) com n_3 neurônios em sua camada de saída, os n_3 desvios (erros) correspondentes entre as respostas desejadas e aquelas geradas pelos neurônios de saída são calculados. Esses desvios são então empregados para ajustar os pesos e limiares de todos os neurônios da camada. Após obter esses valores de erro, inicia-se a segunda fase do método *backpropagation*, denominada "propagação inversa" (*backward*). Nesta fase, ocorrem as modificações (ajustes) dos pesos sinápticos e limiares de todos os neurônios da rede, diferentemente da etapa anterior, focada na avaliação e cálculo dos erros (Haykin, 2001).

Os sistemas de aquisição de dados devem atuar em conjunto com as redes neurais artificiais. Eles são responsáveis por capturar os dados provenientes de sensores e realizar uma preparação de informações em formatos adequados para alimentar as redes neurais. Para a aquisição dos dados será utilizado um sensor de temperatura DS18B20 e uma placa Arduino UNO, responsável por enviar os valores para o *software Node-Red* e armazená-los em tabela Excel. Essa tabela é utilizada para treinamento e validação de uma RNA no *software MatLab*. Os aspectos relacionados ao *hardware* e *software* que podem ser aplicados na aquisição de sinais estão detalhados a seguir.

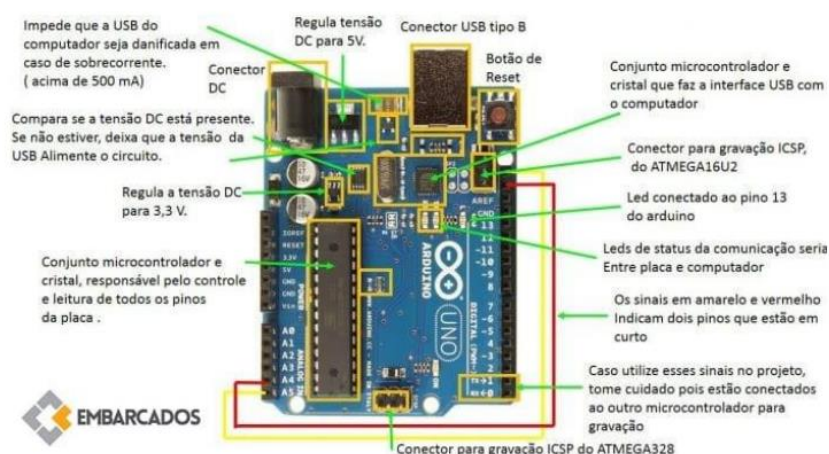
2.4. Hardware e software aplicados para a aquisição de sinais

2.4.1 Arduino UNO

O Arduino foi criado em 2005 por um grupo de pesquisadores italianos, com o propósito de elaborar um dispositivo barato, fácil de programar, funcional e acessível para estudantes e projetistas. O conceito de *hardware* livre acompanha o Arduino, dessa forma, torna-se possível melhorar, modificar, personalizar o Arduino, tendo como princípio o mesmo *hardware* básico (Teles, 2016).

Segundo Rocha (2019), apesar de não ter a opção de fazer *debug*, trata-se de uma ótima ferramenta para quem está estudando o assunto ou para quem deseja fazer simulação de projetos antes de partir para uma placa finalizada, com os componentes soldados. É simples e possui características de *hardware* mínimas, mas que atendem perfeitamente vários tipos de projetos. A conectividade *USB* e a facilidade em programar são atrativos diferenciados e que possuem grande importância para quem busca fazer projetos destinados ao Arduino. A Figura 6 ilustra as principais partes que compõem o Arduino UNO.

Figura 6 - Componentes do Arduino Uno



Fonte: Rocha, 2019

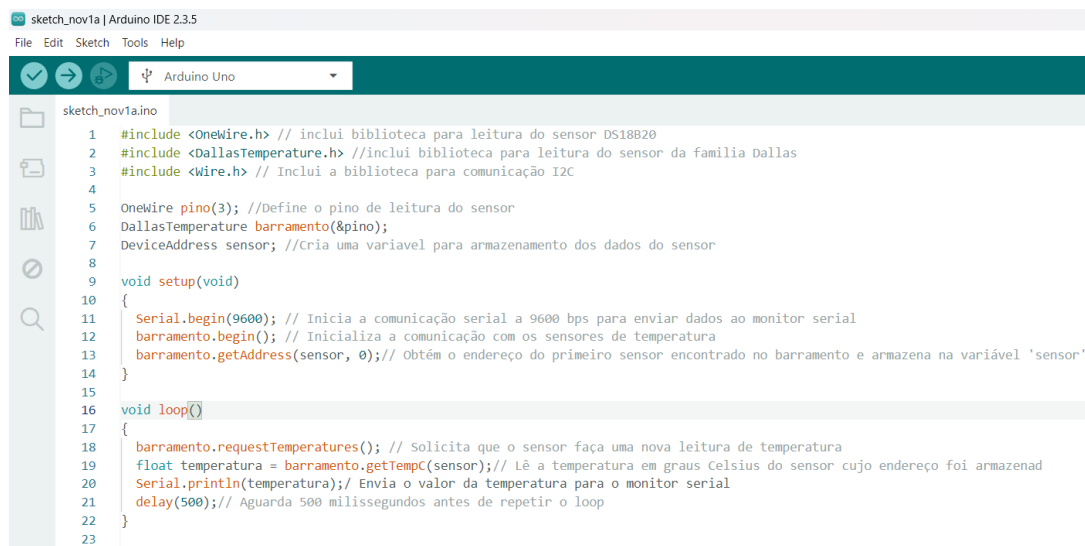
2.4.2 Interface de Desenvolvimento e Linguagem de Programação

Segundo Silva e Paulo Henrique de Oliveira (2013), para utilizar um Arduino é necessário o aplicativo de uma Interface de Desenvolvimento (IDE), onde todo o código é desenvolvido antes de enviar o programa para a *hardware*.

O código escrito para o Arduino é estruturado por duas partes básicas. A primeira é chamada de *setup()* – nesta etapa as opções iniciais do programa são definidas e escritas. Nessa parte, é possível definir se uma porta será usada como entrada ou saída. Na segunda etapa, chamada de *loop()*, é escrita a estrutura de

comandos que será executada de forma constante, ou até que um comando de “pare” seja enviado ao Arduino, conforme a Figura 7.

Figura 7 - Código Arduino IDE



```
1 #include <OneWire.h> // inclui biblioteca para leitura do sensor DS18B20
2 #include <DallasTemperature.h> //inclui biblioteca para leitura do sensor da familia Dallas
3 #include <Wire.h> // Inclui a biblioteca para comunicação I2C
4
5 OneWire pino(3); //Define o pino de leitura do sensor
6 DallasTemperature barramento(&pino);
7 DeviceAddress sensor; //cria uma variavel para armazenamento dos dados do sensor
8
9 void setup(void)
10 {
11   Serial.begin(9600); // Inicia a comunicação serial a 9600 bps para enviar dados ao monitor serial
12   barramento.begin(); // Inicializa a comunicação com os sensores de temperatura
13   barramento.getAddress(sensor, 0); // Obtém o endereço do primeiro sensor encontrado no barramento e armazena na variável 'sensor'
14 }
15
16 void loop()
17 {
18   barramento.requestTemperatures(); // Solicita que o sensor faça uma nova leitura de temperatura
19   float temperatura = barramento.getTempC(sensor); // Lê a temperatura em graus Celsius do sensor cujo endereço foi armazenad
20   Serial.println(temperatura); // Envia o valor da temperatura para o monitor serial
21   delay(500); // Aguarda 500 milissegundos antes de repetir o loop
22 }
23
```

Fonte: Do Autor (2025).

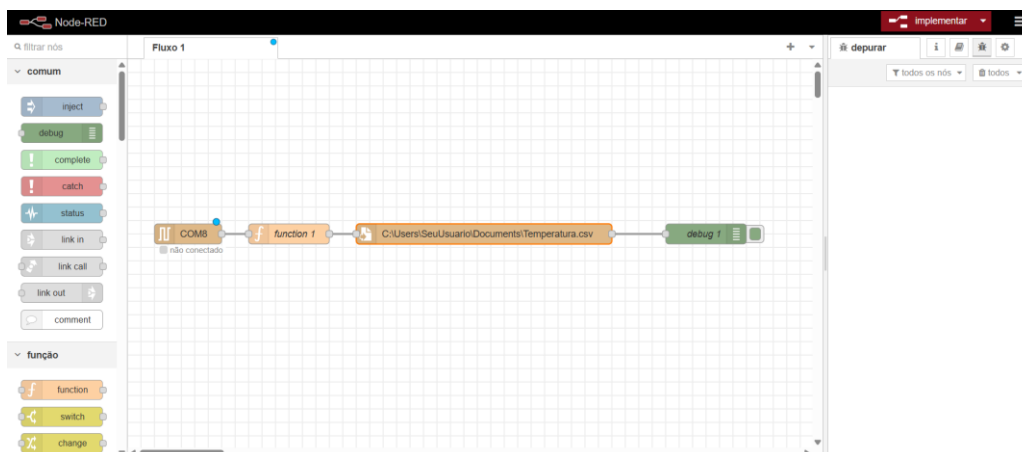
2.4.3 Node-Red

A ferramenta *Node-RED* foi desenvolvida pela IBM para o ensino de *IoT*, e permite aos programadores modelar, implementar e validar diversas aplicações usando uma interface interativa, amigável e com uma curva rápida de aprendizado. A metodologia utilizada é a de projetos e ensino com exemplos (Ferreira, 2017).

O *Node-RED* opera em código aberto e permite a programação através de fluxos (*flow-based programming*), usando uma interface no navegador. A plataforma possui vários nós com diferentes funcionalidades que podem ser conectados de forma coerente permitindo a passagem do fluxo de informações e criando aplicações. O princípio é simples, cada nó possui uma funcionalidade bem definida e a maioria dos nós abstrai a implementação do programador (Ferreira, 2017).

A Figura 8 ilustra os nós utilizados na programação do *Node-Red* com a finalidade de armazenar os dados de temperatura vindos no Arduino via comunicação serial em planilha *Excel*.

Figura 8 - Plataforma *Node-Red*



Fonte: Do Autor (2025)

2.4.4 Sensor de temperatura DS18B20

O sensor de temperatura DS18B20 é um dispositivo que responde a um estímulo físico ou químico de maneira específica, produzindo um sinal que pode ser transformado em outra grandeza física para fins de medição e/ou monitoramento, geralmente um sinal elétrico. O sensor DS18B20, produzido pela empresa de semicondutores *Dallas Semiconductor* é um termômetro digital com resolução programável de 9 a 12 *bits* e interface de comunicação exclusiva 1-Wire, que requer apenas um pino de porta para comunicação, seu range de medição varia de -55°C até $+125^{\circ}\text{C}$, a qual possui uma precisão de $\pm 0,5^{\circ}\text{C}$ entre valores de -10°C à $+85^{\circ}\text{C}$ (Semiconductor, 2014).

2.4.5 Software *MATLAB*

O *MATLAB*, desenvolvido pela empresa norte americana *MathWorks*, é uma poderosa plataforma de computação técnica que se destaca como uma ferramenta essencial para uma ampla gama de aplicações em ciência, engenharia e pesquisa. Seu nome, derivado do termo "*Matrix Laboratory*" ou "Laboratório de Matrizes", reflete a ênfase na manipulação eficiente de matrizes, proporcionando um ambiente

computacional altamente eficaz para análise numérica, modelagem matemática, simulação e desenvolvimento de algoritmos (Mathworks, 2023).

A interface gráfica do *MATLAB* facilita a representação visual de dados e resultados, contribuindo para uma compreensão mais intuitiva e eficaz dos problemas abordados. Além de sua estrutura central robusta, o *MATLAB* destaca-se pela extensa coleção de *toolboxes* especializadas, que ampliam ainda mais suas capacidades e adaptam o *software* a uma variedade de domínios específicos. Os *toolboxes* oferecem conjuntos de funções, algoritmos e recursos dedicados a áreas como processamento de sinais, processamento de imagens, controle de sistemas dinâmicos, estatísticas e muitas outras disciplinas.

A *toolbox* de Redes Neurais Artificiais, por exemplo, proporciona ferramentas avançadas para o *design*, treinamento e implementação de redes neurais em projetos de aprendizado de máquina e inteligência artificial. Essa abordagem modular e expansível, característica dos *toolboxes* do *MATLAB*, confere aos usuários a flexibilidade de adaptar a plataforma às demandas específicas de seus projetos, consolidando o *MATLAB* como uma ferramenta essencial e abrangente para a comunidade técnica e científica (Mathworks, 2023).

A Seção 3 descreve a metodologia adotada neste trabalho, incluindo a coleta e validação dos dados de temperatura no estator do motor, a instalação do sensor DS18B20, a programação no Arduino para leitura dos dados, e sua transferência via Node-Red para planilha Excel. Esses dados foram utilizados no *MATLAB* para treinar uma Rede Neural Artificial voltada à predição de temperatura, visando à aplicação em manutenção preditiva.

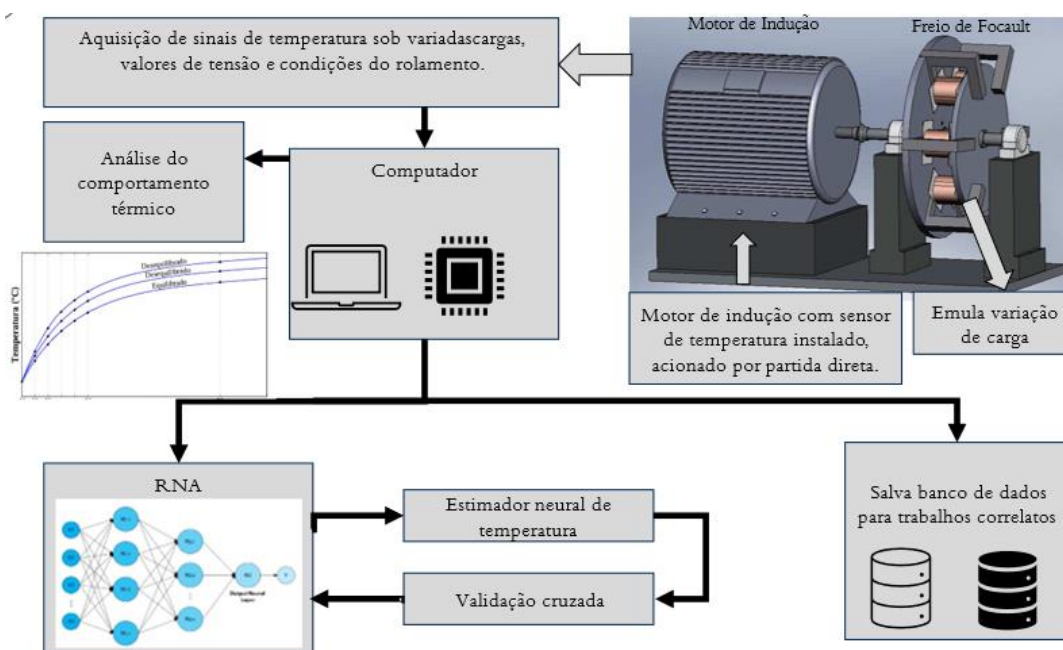
3 METODOLOGIA

Este trabalho apresenta uma estratégia para monitorar e estimar a temperatura de motores de indução trifásicos (MIT) utilizando sensores de baixo custo e redes

neurais artificiais. Para isso, uma bancada experimental foi utilizada para a coleta e validação dos dados. A Figura 9 ilustra a metodologia utilizada neste trabalho.

Na Figura 9, o sistema experimental inicia-se com a aquisição de sinais de temperatura, realizados sob diferentes condições operacionais, variando-se cargas, tensões e estados do rolamento. Esses dados são coletados de um motor de indução instrumentado com sensores de temperatura e acoplado a um freio de Foucault, que emula a variação de carga no eixo do motor. O motor é acionado em regime de partida direta, simulando condições típicas de operação industrial. Os sinais coletados são processados por um computador, que realiza a análise do comportamento térmico do motor, como ilustrado no gráfico de evolução de temperatura até o equilíbrio térmico.

Figura 9 - Fluxograma dos testes para validação do trabalho.



Fonte: Do Autor (2025).

Os dados processados alimentam dois fluxos simultâneos: um banco de dados e uma rede neural. No primeiro fluxo, os dados são armazenados em um banco de dados para futuras análises e comparações em trabalhos correlatos. No segundo


fluxo, os dados alimentam uma Rede Neural Artificial (RNA), que atua como um estimador neural de temperatura.

A rede é treinada e validada utilizando técnicas de validação cruzada, garantindo a robustez e a generalização do modelo desenvolvido. A metodologia propõe que o modelo de RNA seja utilizado para prever o comportamento térmico do motor, reduzindo a necessidade de ensaios experimentais exaustivos e permitindo a análise preditiva de falhas térmicas.

3.1 Bancada de testes

Com o objetivo de prever prováveis falhas térmicas em motores de indução trifásicos, o desenvolvimento da metodologia dessa pesquisa tem como objetivo submeter um MIT a vários testes com condições reais de trabalho, sobrecargas mecânicas, rolamento com tempo de vida útil elevado (rolamento ruim), afundamento de tensão (baixa tensão) e sobre tensão (tensão alta). Para a realização dos experimentos, foi utilizada uma bancada de testes de Máquinas Elétricas Rotativas ilustrada na Figura 10.

Figura 10 – Sistema Didático de Máquinas Elétricas e Geradoras




Fonte: Do Autor (2025).

A referida bancada de testes possibilita emular variações de cargas mecânicas no eixo do MIT através de um freio de *Focault*. Além do conjugado mecânico, também é possível testar o motor com um variador de tensão (*Variac*), que possibilita aplicar tensões variadas no motor (menores ou maiores do que a tensão nominal de trabalho).

Para a realização dos testes, foi utilizado um motor de indução – gaiola WEG W22 *Premium* modelo 80 com potência de 0,75 kW ou 1CV e corrente nominal de 2,89 Amperes, acionado em tensão de 220Vca. O referido motor possui um Fator de Serviço (FS) de 1,25. O FS trata-se de um valor multiplicador que indica a carga que o motor pode operar acima de suas condições nominais).

Segundo Guarnieri; Samuel Cerrutia (2017), de maneira geral, sobrecargas leves, como em torno do FS, não são tão prejudiciais para a máquina, assim como pequenos transientes de sobrecarga. O grande fator a ser levar em conta é a temperatura nos enrolamentos, se o motor apresentar ventilação deficiente, por exemplo, até o regime nominal, pode estar fazendo que a máquina exceda o limite de temperatura da classe de isolamento, essas condições diminuem muito a vida útil do MIT. Os dados do motor são ilustrados na placa de identificação da Figura 11.

Figura 11 - Placa de Identificação do MIT




Fonte: Do Autor (2025)

Conforme o catálogo WEG (2021) o motor utiliza a classes de isolamento B (120°C). Adicionalmente, é projetado para trabalhar em um ambiente com temperatura de até 40°C em uma altitude de até 1000m. O delta T (ΔT) é a diferença de temperatura entre o bobinado do motor e a temperatura ambiente, ou seja, os motores standard com isolação B possuem um delta ΔT de 80°C. A próxima subseção apresentada os procedimentos práticos para o desenvolvimento da metodologia dessa pesquisa.

3.2 Aquisição de dados

A aquisição dos valores de temperatura foi realizada com um sensor de temperatura - modelo DS18B20, instalado diretamente nas bobinas do estator do MIT. Para obter acesso as bobinas, foi necessário desmontar o motor e amarrar o sensor diretamente em suas bobinas conforme ilustra a Figura 12, garantido confiabilidade e precisão nos valores obtidos.

Figura 12 – Sensor de temperatura instalado nas bobinas do estator do MIT



Fonte: Do Autor (2025).

O sensor foi conectado à placa Arduino UNO pela porta digital 3, utilizando um resistor de 4K7 ohm do tipo pull-up para assegurar a comunicação 1-Wire eficiente, mantendo o sinal em nível alto mesmo na ausência de leitura. A Figura 13 apresenta o esquema de ligação.

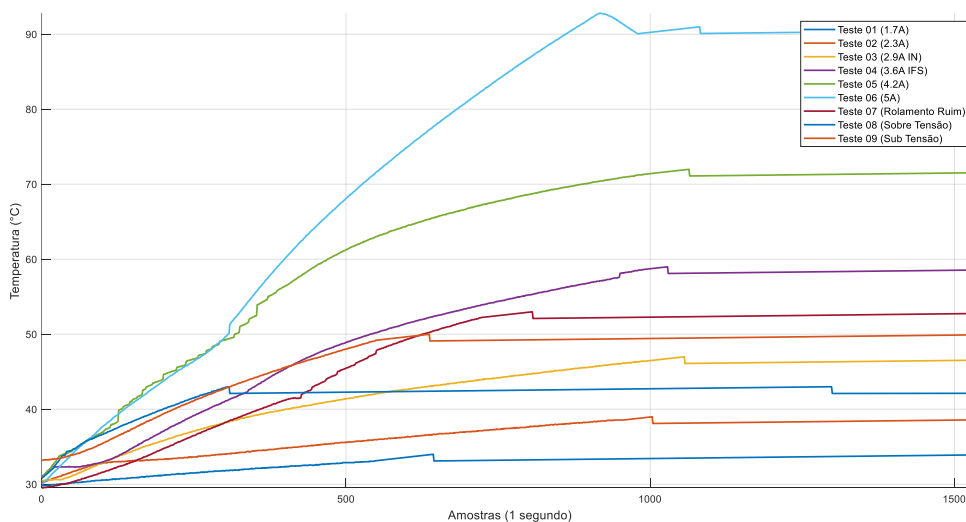
Tabela 1 – Parcial dos testes de temperatura no bobinado do MIT

Modelo de testes para análise de variação de temperatura em MIT								
1,6 Amperes	2,2 Amperes	2,9 Amperes - IN	3,6 Amperes - IFS - 125% IN	4,2 Amperes - 145% IN	5 Amperes - 172% IN	Rolamento Ruim	Afundo de tensão - 170Vca	Sobre tensão - 255Vca
29.81	30.19	30.50	30.92	30.86	30.00	29.50	30.78	30.86
29.81	30.25	30.50	30.99	30.94	30.06	29.50	30.86	30.94
29.81	30.31	30.50	31.15	31.05	30.06	29.50	30.93	31.05
29.81	30.37	30.50	31.20	31.16	30.25	29.56	30.99	31.16
29.81	30.37	30.50	31.26	31.28	30.31	29.56	31.08	31.28
29.81	30.44	30.50	31.36	31.35	30.37	29.56	31.17	31.35
29.81	30.37	30.56	31.40	31.50	30.50	29.56	31.25	31.50
29.81	30.44	30.56	31.55	31.56	30.56	29.56	31.29	31.56

Fonte: Do Autor (2025).

A planilha completa foi adicionada a programação de uma RNA em uma toolbox no software MATLAB. Com o objetivo de validar a coleta de dados e dar sequência a etapa de treinamento da RNA para predição de temperatura, os dados coletados e anexados em Excel foram plotados no MATLAB para se analisar a coerência do gráfico fornecido pela rede. A Figura 13 ilustra as curvas de temperatura de cada teste realizado, demonstrando variações de temperatura dependendo das condições em que o MIT foi submetido.

Figura 13 – Gráfico da temperatura em diferentes experimentos.



Fonte – Do Autor (2025).

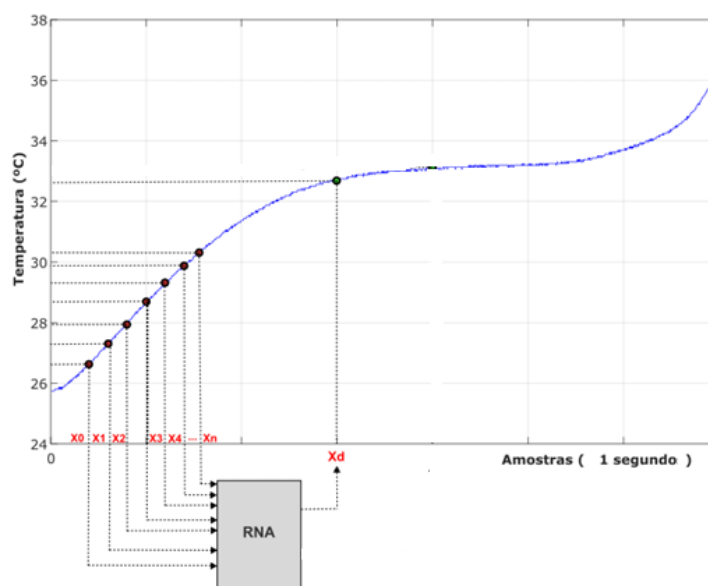
A seguir são detalhados os aspectos relacionados as topologias adotadas para o treinamento do preditor neural.

3.3 Predição de temperatura utilizando redes neurais

Este trabalho adotou o uso das redes neurais temporais com entradas deslocadas no tempo, conhecidas como Time-Delay Neural Networks (TDNN). Essas redes são arquiteturas especialmente projetadas para processar sinais sequenciais ou séries temporais, capturando a dependência temporal entre os dados. Diferentemente das redes *feedforward* tradicionais, a TDNN introduz deslocamentos (*delays*) explícitos nas entradas, permitindo que o modelo considere não apenas o valor atual do sinal, mas também uma janela de valores passados.

Essa característica torna a TDNN particularmente eficaz na modelagem de fenômenos dinâmicos, como o comportamento térmico de motores elétricos ou o reconhecimento de padrões em sinais de voz, uma vez que ela consegue identificar relações de causa e efeito distribuídas ao longo do tempo. A estruturação da rede neural utilizada está apresentada na Figura 14,

Figura 14 – Metodologia do preditor neural



Fonte: Do Autor (2025).

Na topologia da Figura 14, os valores de x_0, x_1, x_2, x_3, x_4 até x_n representam o intervalo de amostras de entrada selecionadas para o treinamento da rede. Esse número representa 67% dos valores da coleta antes da temperatura em regime permanente, ou seja, o número indicado para treinamento de uma rede neural é 67% da parte transitória da temperatura. O valor após o bloco de Rede Neural Artificial (RNA) nomeado X_d é o valor de predição da rede, esse valor pode ser determinado no código dependendo da posição desejada para análise.

A topologia utilizada permite alterações de parâmetros que impactam no seu desempenho, alguns exemplos são: o número de camadas da rede, o número de neurônios de cada camada, o método de aprendizado utilizado, o coeficiente de aprendizado, o número de épocas e o erro quadrático médio (MSE), entre outros.

Após a coleta os dados foram estruturados e separados em seus determinados arquivos (Dados_temp (todos os dados coletados), Dados_Treinamento (% dos dados coletados separada para treinamento) e D (que são os resultados desejados para predição da rede). A seguir são apresentadas as tabelas com os parâmetros utilizados nos treinamentos da RNA.

Quadro 1 - Topologia n° 1 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	2	
N° de Neurônios camada 1	6	
N° de Neurônios camada 2	1	
Algoritmo de Treinamento	Gradiente Descendente	
Função de Ativação camada 1	tansig	
Função de Ativação camada 2	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-8	
Coeficiente de aprendizado	0.001	
N° de dados para treinamento da rede	569 amostras ou 67%	

Fonte: Do Autor (2025).

Quadro 2 - Topologia n° 2 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	4	
N° de Neurônios camada 1	75	
N° de Neurônios camada 2	5	
N° de Neurônios camada 3	2	
N° de Neurônios camada 4	1	
Algoritmo de Treinamento	Gradiente Descendente com Momentun	
Função de Ativação camada 1	tansig	
Função de Ativação camada 2	tansig	
Função de Ativação camada 3	tansig	
Função de Ativação camada 4	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-8	
Coeficiente de aprendizado	0.01	
N° de dados para treinamento da rede	569 amostras ou 67%	

Fonte: Do Autor (2025).

Quadro 3 - Topologia n° 3 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	3	
N° de Neurônios camada 1	150	
N° de Neurônios camada 2	50	
N° de Neurônios camada 3	1	
Algoritmo de Treinamento	Gradiente Descendente com Momentun	
Função de Ativação camada 1	logsig	
Função de Ativação camada 2	logsig	
Função de Ativação camada 3	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-6	
Coeficiente de aprendizado	0.01	
N° de dados para treinamento da rede	569 amostras ou 67%	

Fonte: Do Autor (2025)

Quadro 4 - Topologia n° 4 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	3	
N° de Neurônios camada 1	300	
N° de Neurônios camada 2	100	
N° de Neurônios camada 3	1	
Algoritmo de Treinamento	Gradiente Descendente com Momentun	
Função de Ativação camada 1	logsig	
Função de Ativação camada 2	logsig	
Função de Ativação camada 3	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-6	
Coeficiente de aprendizado	0.01	
N° de dados para treinamento da rede	569 amostras ou 67%	

Fonte: Do Autor (2025).

Quadro 5 - Topologia n° 5 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	3	
N° de Neurônios camada 1	10	
N° de Neurônios camada 2	8	
N° de Neurônios camada 3	1	
Algoritmo de Treinamento	Gradiente Descendente com Momentun	
Função de Ativação camada 1	logsig	
Função de Ativação camada 2	logsig	
Função de Ativação camada 3	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-6	
Coeficiente de aprendizado	0.001	
N° de dados para treinamento da rede	349 amostras ou 38%	

Fonte: Do Autor (2025).

Quadro 6 - Topologia n° 6 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	3	
N° de Neurônios camada 1	15	
N° de Neurônios camada 2	4	
N° de Neurônios camada 3	1	
Algoritmo de Treinamento	Gradiente Descendente com Momentun	
Função de Ativação camada 1	logsig	
Função de Ativação camada 2	logsig	
Função de Ativação camada 3	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-8	
Coeficiente de aprendizado	0.01	
N° de dados para treinamento da rede	349 amostras ou 38%	

Fonte: Do Autor (2025).

Quadro 7 - Topologia n° 7 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	3	
N° de Neurônios camada 1	150	
N° de Neurônios camada 2	50	
N° de Neurônios camada 3	1	
Algoritmo de Treinamento	Gradiente Descendente com Momentun	
Função de Ativação camada 1	logsig	
Função de Ativação camada 2	logsig	
Função de Ativação camada 3	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-6	
Coeficiente de aprendizado	0.001	
N° de dados para treinamento da rede	349 amostras ou 38%	

Fonte: Do Autor (2025).

Quadro 8 - Topologia n° 8 para o estimador neural

Arquitetura	PMC	
Treinamento	"traingdm"	
N° de Camadas	3	
N° de Neurônios camada 1	15	
N° de Neurônios camada 2	5	
N° de Neurônios camada 3	1	
Algoritmo de Treinamento	Gradiente Descendente com Momentun	
Função de Ativação camada 1	logsig	
Função de Ativação camada 2	logsig	
Função de Ativação camada 3	purelin	
N° de Épocas	5000	
Erro Quadrado Médio	1e-6	
Coeficiente de aprendizado	0.001	
N° de dados para treinamento da rede	297 amostras ou 33%	


Fonte: Do Autor (2025).

Os quadros citados acima são as topologias utilizadas para os treinamentos que tiveram os melhores resultados para predição de temperatura desejada. A Figura 15 detalha o janelamento dos dados para treinamento. Durante os ensaios, foram coletadas 1400 amostras, dentre as quais, o regime transitório representa aproximadamente 900 amostras, ou seja, os 100% dos dados utilizados.

Todas as topologias citadas foram treinadas para que a rede estime a temperatura na amostra número 1000 no gráfico. O sistema de aquisição de dados foi estipulado para registrar uma amostra por segundo, assim sendo, o estimador neural é capaz de prever a temperatura em um tempo de 16 minutos e 40 segundos à frente.

Para as topologias 1, 2, 3 e 4 foram utilizadas 569 amostras (67%) que representam 9 minutos e 29 segundos de coleta de dados. As topologias 5, 6 e 7 utilizaram 349 amostras (38%) que representam 5 minutos e 49 segundos de coleta de dados. Por fim, a topologia 8 utilizou 297 amostras (33%) que representa 4 minutos e 57 segundos de coleta de dados.

Figura 15 – Gráfico demonstrativo da utilização dos dados coletados



Fonte: Do Autor (2025).

As porcentagens de amostras separadas para os treinamentos foram retiradas somente do período da temperatura em regime transitório. Assim, foram consideradas 900 amostras (15 minutos de teste) o total de 100% e não as 1400 amostras totais que têm um tempo de teste de 23 minutos e 20 segundos.

A próxima sessão apresenta a discussão dos resultados obtidos com os treinamentos listados nos quadros 1 a 8, com o intuito de apresentar o modelo com melhor desempenho e resultado, porém, destacando as qualidades dos demais testes, tendo em vista que todos os modelos acima têm potencial para serem utilizados de maneira efetiva, trazendo resultados satisfatórios.

Vale destacar que os gráficos apresentados nos resultados são as curvas de temperatura dos testes 5 (4,2Amperes-145%-IN) e 6 (5Amperes-172%-IN) e foram utilizados em todas as topologias.

4. APRESENTAÇÃO DE DISCUSSÃO DOS RESULTADOS

Nesta análise dos resultados, serão detalhadas as diferenças entre os treinamentos descritos na seção de Metodologia. Para sistemas de primeira ordem, diversas referências apontam a utilização de 2/3 ou 67% dos dados como um valor adequado para a modelagem do sistema por meio de sua função de transferência. O presente estudo visa encontrar configurações de rede que tragam resultados satisfatórios com uma quantidade menor de dados utilizados para treinamento.

O quadro 9 ilustra as configurações das quatro topologias da rede (Top. 1 – 4) utilizada como preditor neural. Nessas topologias foram utilizadas 67% dos dados para o treinamento da rede.

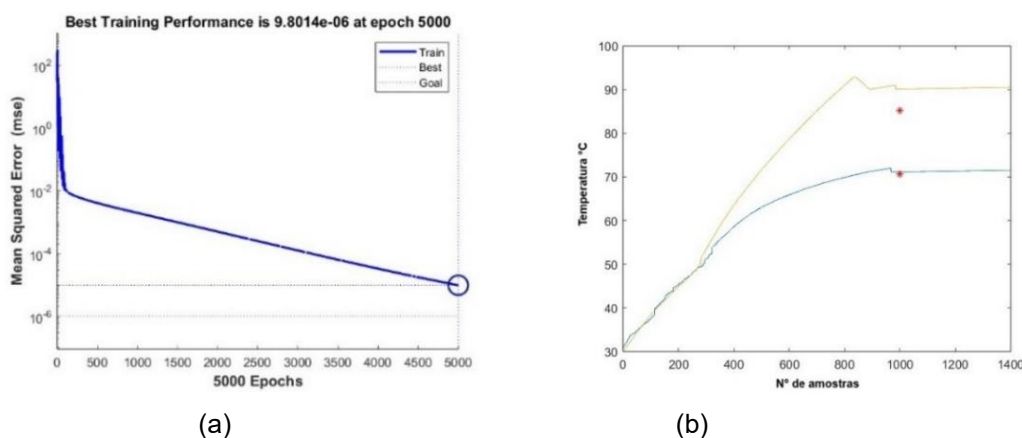
Quadro 9 – Comparação de estruturas da RNA

	Top. 1	Top. 2	Top. 3	Top. 4
Arquitetura	PMC	PMC	PMC	PMC
Treinamento	“traingdm”	“traingdm”	“traingdm”	“traingdm”
Nº de Camadas	2	4	3	3
Nº de Neurônios camada 1	6	75	150	300
Nº de Neurônios camada 2	1	5	50	100
Nº de Neurônios camada 3		2	1	1
Nº de Neurônios camada 4		1		
Algoritmo de Treinamento	GD	GD+M	GD+M	GD+M
Função de Ativação camada 1	tansig	tansig	logsig	logsig
Função de Ativação camada 2	purelin	tansig	logsig	logsig
Função de Ativação camada 3		tansig	purelin	purelin
Função de Ativação camada 4		purelin		
Nº de Épocas	5000	5000	5000	5000
Erro Quadrado Médio	1e-8	1e-8	1e-6	1e-6
Coeficiente de aprendizado	0.001	0.01	0.01	0.01
Qtde. dados para treinamento	67%	67%	67%	67%

Fonte: Do Autor (2025)

Comparando as topologias utilizadas nos treinamentos, a que apresentou o melhor resultado foi a topologia 4 que teve uma taxa de erro de 0,1195%. O treinamento foi interrompido na época 5000 com um erro final de $9.9427e-07$ o que atinge a meta definida de $1e-6$, com um valor da saída Y muito próximo ao valor desejado D com assertividade de 99,8895% como ilustra a Figura 15. Os demais treinamentos também apresentaram valores esperados.

Figura 15 – Topologia 4: (a) performance; (b) validação

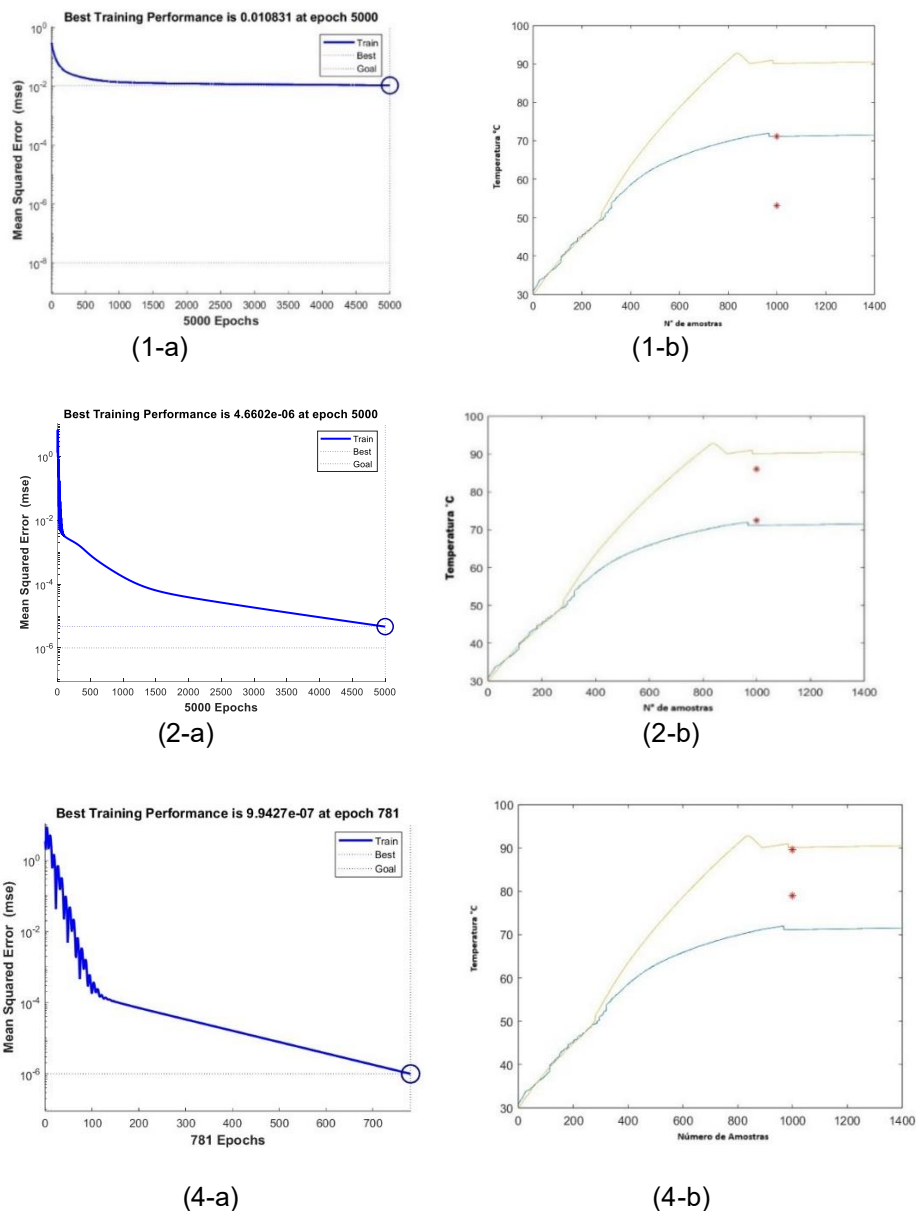


Fonte: Do Autor (2025).

A Figura 16 apresenta os gráficos de desempenho e validação das topologias 1, 2 e 4 do preditor neural. As subfiguras (1-a), (2-a) e (4-a) mostram a evolução do erro quadrático médio (MSE) ao longo das épocas de treinamento. Observa-se que todas as topologias convergiram, embora a topologia 4 tenha alcançado o menor erro ($\approx 8,9 \times 10^{-6}$), indicando melhor desempenho entre as três.

Nas subfiguras (1-b), (2-b) e (4-b), a validação da estimativa de temperatura mostra a aproximação entre os valores reais e os preditos pela rede. A topologia 4 (4-b) apresenta uma curva predita mais aderente aos dados reais, com menor dispersão dos pontos de erro, o que reforça sua maior assertividade. Já as topologias 1 e 2 demonstram maior desvio entre as curvas, especialmente em regiões de temperatura mais elevada, indicando menor precisão preditiva.

Figura 16 – Topologia 1, 2 e 3: (a) performance; (b) validação



Fonte: Do Autor (2025).

Nas subfiguras (1-b), (2-b) e (4-b), a validação da estimativa de temperatura mostra a aproximação entre os valores reais e os preditos pela rede. A topologia 4 (4-b) apresenta uma curva predita mais aderente aos dados reais, com menor dispersão dos pontos de erro, o que reforça sua maior assertividade. Já as topologias 1 e 2 demonstram maior desvio entre as curvas, especialmente em regiões de temperatura

mais elevada, indicando menor precisão preditiva. O Quadro 10 ilustra os resultados de assertividade e taxa de erro das topologias.

Quadro 10 – Resultados da Rede Neural utilizando 67% dos dados para o treinamento.

	D-71,1310	D-90,1150	Assertividade 1	Assertividade 2	Erro 1	Erro 2
Top. 1	Y 70,0873	Y-53,1851	98,9563%	63,0701%	1,0437%	36,9299%
Top. 2	Y-73,6450	Y-86,4062	97,486%	96,2912%	2,514%	3,7088%
Top. 3	Y-74,9040	Y-89,6237	96,227%	99,5087	3,773%	0,4913
Top. 4	Y-71,0205	Y-85,3286	99,8895%	95,2136%	0,1105%	4,7864%

Fonte: Do Autor (2025).

No Quadro 10: D são os valores desejados; Y são os valores obtidos com o treinamento; Assertividade 1 e erro 1 serão referentes à linha azul do gráfico; e assertividade 2 e erro 2 à linha laranja, demonstrando a eficiência e precisão dos treinamentos.

Na sequência, são apresentadas as topologias e os resultados obtidos utilizando o número de dados para treinamento menor que o normalmente utilizado, como mostra o Quadro 11. Os treinamentos a seguir apresentaram resultados satisfatórios, com destaque para a topologia 8, que conseguiu bons resultados utilizando apenas 33% de dados para treinamento, como mostra a Figura 17.

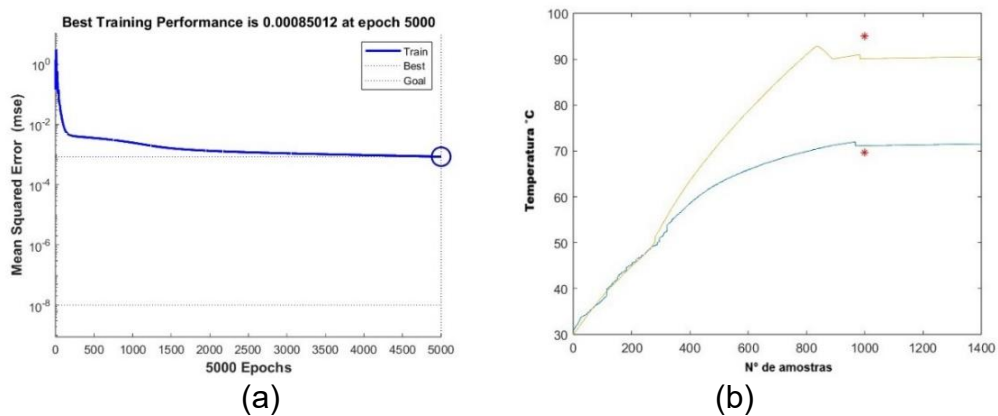
Quadro 11 – Comparação de estruturas da RNA

	Top. 5	Top. 6	Top. 7	Top. 8
Arquitetura	PMC	PMC	PMC	PMC
Treinamento	“traingdm”	“traingdm”	“traingdm”	“traingdm”
Nº de Camadas	3	3	3	3
Nº de Neurônios camada 1	10	15	150	15
Nº de Neurônios camada 2	8	4	50	5

N° de Neurônios camada 3	1	1	1	1
N° de Neurônios camada 4				
Algoritmo de Treinamento	GD	GD+M	GD+M	GD+M
Função de Ativação camada 1	logsig	logsig	logsig	logsig
Função de Ativação camada 2	logsig	logsig	logsig	logsig
Função de Ativação camada 3	purelin	purelin	purelin	purelin
Função de Ativação camada 4				
N° de Épocas	5000	5000	5000	5000
Erro Quadrado Médio	1e-6	1e-8	1e-6	1e-9
Coeficiente de aprendizado	0.001	0.01	0.001	0.001
Qtde. dados para treinamento	38%	38%	38%	33%

Fonte: Do Autor (2025).

Figura 17 – Topologia 8: (a) performance; (b) validação



Fonte: Do Autor (2025)

Os testes 5, 6, 7 e 8 atingiram o limite de épocas estipulados para finalizar o treinamento, entretanto, demonstraram eficiência e precisão mesmo com o número de dados muito menor que o recomendado pelas literaturas para os treinamentos. O Quadro 12 ilustra os resultados de assertividade e taxa de erro das topologias.

Quadro 12 – Resultados da Rede Neural utilizando 38% e 33% dos dados para o treinamento.

	D-71,1310	D-90,1150	Assertividade 1	Assertividade 2	Erro 1	Erro 2
Top. 5	Y- 70,6260	Y- 85,1915	99,495%	95,0765%	0,0505%	4,9235%
Top. 6	Y- 74,3773	Y- 87,5613	96,7537%	97,4463%	3,2463%	2,5537%
Top. 7	Y- 71,6814	Y- 70,7071	99,4496%	80,5921%	0,5504%	19,4097%
Top. 8	Y- 69,7113	Y- 93,9340	98,5803%	96,181%	1,4197%	3,819%

Fonte: Do Autor (2025)

Ao analisar todos os dados apresentados percebe-se que a topologia com o melhor resultado foi a Rede 4 que apresentou 99,8895% e 95,136% de assertividade, entretanto utilizando o valor total de épocas para finalizar seu treinamento. Outra topologia em destaque é a Rede 3 pois apresentou uma assertividade de 96,227% e 99,5087% com apenas 15,62% ou 781 do número de épocas estipulado para treinamento, isso significa que a rede estimou o valor de temperatura desejado muito mais rápido que os demais treinamentos que utilizaram 67% do total de dados para realizar o treinamento.

Outro resultado em destaque foi a topologia 8, que mesmo utilizando o valor máximo de épocas para treinamento conseguiu taxa de assertividade e erro satisfatórios para essa pesquisa utilizando apenas 33% de dados para treinamento da rede sem reduzir drasticamente a precisão dos resultados.

5 CONSIDERAÇÕES FINAIS

A proposta deste trabalho consiste na implementação de uma metodologia para um estimador de temperatura em motores de indução trifásicos utilizando redes neurais artificiais. O estudo partiu das coletas dos dados de temperatura submetendo o MIT em diversas condições de trabalho, desde condições normais á condições adversas (sobrecargas e nível de tensão não compatível com o motor), uma estrutura foi montada para aquisição e planilhamento dos dados coletados. Com os dados

estruturados foram geradas topologias para treinamento e validação da proposta dessa pesquisa.

Através dos resultados apresentados pelas redes evidencia-se que existem diversas topologias que podem ser aplicadas para predição de temperatura e que redes neurais artificiais podem ser utilizadas na prevenção de falhas de MIT, os treinamentos mostraram valores de predição satisfatórios, obtendo percentuais de assertividade de até 99,8895 %, proporcionando uma nova alternativa para a aplicação em sistemas de identificação de falhas em motores elétricos. Nota-se que mesmo reduzindo os níveis de processamento da rede através da redução dos dados de entrada, a assertividade se mantém elevada, na faixa de 98,5803%.

Entretanto, algumas limitações foram observadas no decorrer do estudo. A principal delas diz respeito ao nível de ruído nos dados coletados, especialmente em situações em que o motor era alimentado por inversores de frequência, o que compromete parcialmente a estabilidade da leitura do sensor. Além disso, o processo de treinamento das RNAs depende de uma etapa prévia de organização dos dados, o que requer conhecimento técnico e tempo para ajuste fino dos parâmetros da rede. Outra limitação está relacionada à restrição do conjunto de testes a um único modelo de motor, o que pode limitar a generalização do modelo para diferentes aplicações industriais.

Como propostas para trabalhos futuros, sugere-se a adoção de técnicas de filtragem de sinais mais robustas para mitigar o ruído induzido por acionamentos eletrônicos, como filtros digitais passa-baixa adaptativos. Além disso, recomenda-se a expansão do banco de dados com diferentes modelos e potências de MITs, de modo a treinar redes mais generalistas. Outro caminho promissor é o uso de inteligência artificial embarcada, com a implementação de modelos leves diretamente em microcontroladores, utilizando bibliotecas de aprendizado de máquina otimizadas para dispositivos de borda (edge computing). Por fim, a aplicação de redes neurais convolucionais ou recorrentes, bem como a comparação com algoritmos alternativos

como máquinas de vetor de suporte (SVM), pode ampliar o escopo e a eficiência da predição térmica em cenários industriais mais complexos.

REFERÊNCIAS

AVOLIO, Edwin. **Uma contribuição ao estudo do comportamento térmico e do desempenho elétrico de motores de indução com rotor em gaiola**. 1992. 191 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, SP, 1992. Orientador: Ernesto Ruppert Filho. Disponível em: <https://repositorio.unicamp.br/acervo/detalhe/42205>. Acesso em: 20 de abr. 2025.

BARBARA, Gustavo Vendrame. **Um estudo sobre multissensoriamento no diagnóstico de falhas em motores de indução trifásicos**. 2023. 170 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Tecnológica Federal do Paraná, Cornélio Procopio, 2023. Disponível em: <https://repositorio.utfpr.edu.br/jspui/handle/1/31972>. Acesso em: 20 abr. 2025.

BONNETT, A. H. AND G. C. SOUKUP. Causes and analysis of stator and rotor failures in three-phase induction motors. **IEEE Trans. Ind. Appl.**, vol. 28, no. 4, pp. 921–937. 1992.

CHAPMAN, S. J. **Fundamentos de Máquinas Elétricas**. Porto Alegre: AMGH, 2013

CHOUDHARY, A. et al. Condition Monitoring and Fault Diagnosis of Induction Motors: A Review. **Archives of Computational Methods in Engineering**, v. 26, n. 4, p. 1221–1238, 2019.

DONOLO, P.; BOSSIO, G.; DE ANGELO, C. Analysis of voltage unbalance effects on induction motors with open and closed slots. **Energy Conversion and Management**, [S.l.], v. 52, n. 5, p. 2024–2030, 2011.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Tradução de Luiz Eduardo Borges de Almeida. 2. ed. Porto Alegre: Bookman, 2001.

KARMAKAR, Subrata; CHATTOPADHYAY, Surajit; MITRA, Madhuchhanda. Induction motor fault diagnosis: approach through current signature analysis. 1. ed. Singapore: **Springer**, 2016. 161 p.

KUMAR, P. N.; VINOThRAJ, C.; ISHA, T. B. Effect of wear and tear bearing fault in induction motor drives using FEM. In: **2018 IEEE International Conference on**

Power Electronics, Drives and Energy Systems (PEDES), 2018, Chennai. Proceedings [...]. [S.I.]: IEEE, 2018.

LIU, Yuqing; CHEN, Zaigang; GE, Xin; WANG, Kaiyun. Surface wear evolution of traction motor bearings in vibration environment of a locomotive during operation. **Science China Technological Sciences**, [S.I.], v. 65, n. 2, p. 358–370, 2022. ISSN 1869-1900.

LOPES, Tiago Drummond; GOEDEL, Alessandro; BRONIERA JUNIOR, Paulo; GRACIOLA, Clayton Luiz; MIZUYAMA, Daniel. Uma abordagem neural no monitoramento preditivo de temperatura num motor de indução trifásico. In: **SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI)**, 14., 2013, Fortaleza. Anais [...]. Fortaleza: SBAI, 2013. p. 1–6. Disponível em: <https://www.sbai2013.ufc.br/pdfs/5487.pdf>. Acesso em: 19 de abr. 2025.

MATHWORKS. **What Is MATLAB?** Disponível em: <https://www.mathworks.com/discovery/what-is-matlab.html>. Acesso em: 5 abr. 2023.

PASSE, Fernando Ferreira; VASCONCELOS, Vanessa Cristiny Rodrigues; CANESCHE, Michael; FERREIRA, Ricardo. Perspectivas sobre o uso do Node-Red na educação em IoT. **International Journal of Computer Architecture Education**, [S.I.], v. 6, n. 1, p. 46–51, 2017.

PINHEIRO, Romário de Mesquita. **Inteligência artificial e imagens termográficas infravermelha para avaliação de secagem de sementes**. 2022. 100 f. Tese (Doutorado em Ciência e Tecnologia de Sementes) – Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, Pelotas, 2022. Disponível em: <http://guaiaca.ufpel.edu.br/xmlui/handle/prefix/13951>. Acesso em: 12 de abr. 2025.

QI, Qinglin; TAO, Fei. Digital twin and big data towards smart manufacturing and Industry 4.0: 360 degree comparison. **IEEE Access**, v. 6, p. 3585–3593, 2018.

ROBLES, E. et al. Advanced power inverter topologies and modulation techniques for common-mode voltage elimination in electric motor drive systems. **Renewable and Sustainable Energy Reviews**, v. 140, p. 110746, 2021.

ROCHA, Lucas Vinícius da Silva. **Automação residencial: microcontrolador Arduino através de uma aplicação web**. 2020. Monografia (Graduação em Engenharia da Computação) – Centro Universitário de Brasília (UniCEUB), Brasília, 2020. Disponível em: <https://repositorio.uniceub.br/jspui/handle/prefix/15101>. Acesso em: 21 de abr. 2025.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes neurais artificiais para engenharia e ciências aplicadas: curso prático**. São Paulo: Artliber Editora, 2010. 399 p.

SILVA, Paulo Henrique de Oliveira. Sistema de segurança de tranca de porta e controle de acesso. 2013. Trabalho de Conclusão de Curso (Graduação em Engenharia da Computação) – Centro Universitário de Brasília (UniCEUB), Brasília, 2013. Disponível em: <https://repositorio.uniceub.br/jspui/handle/235/4916>. Acesso em: 14 de abr. 2025

SUETAKE, Marcelo. **Sistemas inteligentes para monitoramento e diagnósticos de falhas em motores de indução trifásicos**. 2012. 191 f. Tese (Doutorado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012. Orientador: Ivan Nunes da Silva. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18153/tde-26062012-164520/>. Acesso em: 20 abr. 2025.

TELES, Elaine. **Arduino: O que é? Para que serve? Quais as possibilidades?** [S. l.], 22 set. 2016. Disponível em: <https://medium.com/nossa-coletividade/arduino-o-que-%C3%A9-pra-que-serve-quais-as-possibilidades-efbd59d33491/> Acesso em: 15 de mar. 2025.

Toliyat, H. A. and G. B. Kliman. **Handbook of Electric Motors**. New York: Marcel Dekker. 2004



Esta obra está licenciada com Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.
[Recebido/Received: Dezembro 18 2024; Aceito/Accepted: Janeiro 29, 2025]