

# Diagnóstico de Falhas em Motores de Indução Trifásicos com Aplicação de Sistemas de Informação e Redes Neurais Artificiais em Sinais Submetidos à Transformação de Clarke

Erick Araujo Nunes\* Bruno Augusto Angélico\*\*  
Alessandro Goedel\*\*\*

\* Departamento de Engenharia de Telecomunicações e Controle,  
Universidade de São Paulo, SP, (e-mail: ericknunes@usp.br).

\*\* Departamento de Engenharia de Telecomunicações e Controle,  
Universidade de São Paulo, SP, (e-mail: angelico@lac.usp.br).

\*\*\* Departamento de Engenharia Elétrica, Universidade Tecnológica  
Federal do Paraná, Cornélio Procópio, PR, (e-mail:  
agoedel@utfpr.edu.br)

---

**Abstract:** This study presents a system for short-circuit fault diagnosis in three-phase induction motors directly connected to the grid. The methodology is based on delayed mutual information in order to extract relevant characteristics relating electrical current signals in  $\alpha - \beta$  orthogonal reference system. Those data are submitted to a multilayer perceptron artificial neural network which performs the pattern classification. Tests considering several operation conditions validate the robustness and accuracy of the proposed methodology.

**Resumo:** Este estudo apresenta um sistema para identificação da falha de curto-circuito em motores de indução trifásicos conectados diretamente à rede. A metodologia do sistema baseia-se na informação mútua deslocada para extração de características relevantes entre sinais de corrente elétrica no sistema de referência ortogonal  $\alpha - \beta$ . Estes dados são submetidos a uma rede neural artificial do tipo perceptron multicamadas para classificação de padrões. Ensaios conduzidos em diversas condições de operação da máquina validam a robustez e precisão da metodologia proposta.

*Keywords:* Induction Motors; Stator Short-Circuit Diagnosis; Mutual Information; Artificial Neural Networks; Clarke Transform.

*Palavras-chaves:* Motores de Indução; Diagnóstico de Curto-Circuito em Estator; Informação Mútua; Redes Neurais Artificiais; Transformação de Clarke.

---

## 1. INTRODUÇÃO

Os Motores de Indução Trifásicos (MIT) consistem em máquinas elétricas cujo fornecimento de energia elétrica é efetuado diretamente pelo estator em corrente alternada (CA). Esta máquina consiste no principal meio de conversão de energia elétrica em energia mecânica motriz em âmbito industrial, fato que se deve às características de baixo custo de aquisição, robustez e simplicidade operacional (Bazan et al., 2020). Entretanto, assim como todo equipamento eletromecânico, os MIT estão sujeitos à ocorrência de desgastes em suas partes.

Com isso, os MIT estão sujeito à falhas de natureza elétrica ou mecânica, de forma a acarretar a perda de desempenho da máquina ainda em estágios iniciais. Devido à relevância dos MIT para os processos industriais modernos, buscam-se maneiras de reduzir os impactos financeiros ou temporais associados às paradas não programadas decorrentes de falhas (Gongora et al., 2016).

Neste contexto, diversos pesquisadores dedicam-se ao estudo de métodos de identificação de falhas nos MIT, diversas propostas são baseadas em sistemas capazes de reconhecer padrões associados a defeitos a partir de leituras de variáveis elétricas, mecânicas ou ambas. As falhas se apresentam frequentemente no estator, rolamentos ou rotor dos MIT. Estudos recentes apontam as falhas de estator como responsáveis por 30% a 40% das ocorrências (Namdar et al., 2022), (Cunha et al., 2021).

Desta maneira, as falhas de estator são classificadas como curto-circuito entre espiras de uma mesma bobina, curto-circuito entre fases e curto-circuito entre fase e terra. Entretanto, os casos mais severos são comumente evoluções do curto-circuito entre espiras, que afetam o material dielétrico empregado para isolamento entre fases ou entre fase e terra. Como se intensificam pela degradação que ocasionam ao material isolante, as falhas de estator podem apresentar evolução acelerada. Assim, a identificação da falha de curto-circuito em estator em seus estágios iniciais é fundamental para garantir a devida tomada de decisão e segurança dos operadores locais (Bazan et al., 2019).

As recentes contribuições são comumente classificadas como estratégias invasivas ou não-invasivas, de acordo com o método de aquisição dos sinais da máquina. Estratégias não-invasivas destacam-se devido à aplicação de elementos de sensoriamento externos aos MIT, sem a necessidade de intervenções no interior das máquinas Bazan et al. (2020).

Assim, aplicam-se diversos métodos com o intuito de identificar de maneira assertiva a ocorrência de falhas em motores de indução trifásicos. Como métodos baseados em estimativa de parâmetros em modelo (Guedes et al., 2019), análises no domínio da frequência (Almounajjed et al., 2021) e análises no domínio do tempo (Godoy et al., 2016). Estudos recentes obtêm resultados promissores mediante a adoção de modelos baseados em inteligência artificial associados aos métodos supracitados (Juez-Gil et al., 2020). Destaca-se a utilização de Redes Neurais Artificiais (RNA), que consistem em modelos computacionais inspirados na forma como o cérebro humano processa informações.

A aderência de redes neurais artificiais à identificação de padrões defeituosos deve-se à sua capacidade de adaptação por experiência e generalização dos resultados obtidos durante a fase de treinamento quando submetidos dados não apresentados anteriormente. Ainda, estes modelos computacionais são aplicáveis para resolução de sistemas não-lineares e independem de modelagens analíticas do sistema (Silva et al., 2016), (Haykin, 2009).

Gongora et al. (2016) empregam redes neurais artificiais para classificação de padrões defeituosos associados à falha de rolamentos a partir de sinais de corrente elétrica amostrados do estator. Nesta estratégia, são observadas variações da intensidade de fluxo magnético a partir da amostragem de corrente elétrica associados aos impactos da vibração mecânica nos componentes dos rolamentos, haja vista às oscilações provocadas no entreferro. Assim, são submetidos sinais no domínio da frequência aplicando-se a transformada rápida de Fourier (*fast Fourier transform - FFT*) associado a um classificador de padrões baseado em redes neurais artificiais para identificação de classes defeituosas.

Godoy et al. (2016) aplicam RNA do tipo *Perceptron* multicamadas (*Multilayer Perceptron - MLP*) e análise de componentes principais (*Principal Component Analysis - PCA*) para classificação da condição de MIT entre saudável e defeituoso mediante os sinais de corrente amostrados para alimentação empregando-se dois modelos distintos de inversores de frequência, submetidos à variação na frequência da tensão de alimentação. Os resultados obtidos demonstram acurácia superior a 80%.

Vitor et al. (2016) dedicam-se ao estudo da identificação de múltiplas falhas em MIT com metodologia baseada nas transformações dos sinais de corrente elétrica em referenciais estacionário e rotativo, mediante a aplicação das respectivas transformações de Clarke e Park. Então, os sinais são decompostos com a aplicação da transformada *Wavelet* e as falhas identificadas a partir de mapas auto-organizáveis de Kohonen (*Self-Organized Maps - SFO*) capazes de formar *clusters* e ativar certos neurônios associados a ocorrência de anomalias específicas.

Guedes et al. (2019) utilizam-se de estratégia baseada em modelo do motor de indução trifásico para estimativa dos parâmetros da máquina com o uso de um algoritmo evolutivo baseado no mecanismo de seleção natural e genética de populações denominado evolução diferencial. Com isso, as variações paramétricas associadas à ocorrência de falhas são passíveis de identificação em máquinas alimentadas diretamente pela rede de energia elétrica.

No campo dos sistemas de informação, Bazan et al. (2019) recorrem à informação mútua atrasada (*Delayed Mutual Information - DMI*) como ferramenta de extração de características. Assim, padrões defeituosos afetam a medida de similaridade entre os sinais de corrente das fases do MIT. A presença de variações associadas a ocorrência de falhas são identificadas por classificadores de padrões baseados em redes neurais artificiais MLP e comparando-os com o classificador baseado em árvore de decisões (*Decision Tree - DT*).

Bazan et al. (2022) abordam os aspectos de desempenho e custo computacional associado à utilização de sistemas de informação para diagnóstico de falhas em MIT, introduzindo uma solução embarcada baseada na DMI. Considera-se a contribuição dos sinais de corrente elétrica de duas fases para composição do sistema de diagnóstico da falha de curto-circuito em estator.

Neste contexto, o presente trabalho visa associar a aplicação de sistemas de informação com a transformação de coordenadas dos três sinais de corrente elétrica do MIT. Desse modo, é extraída a similaridade entre sinais de corrente elétrica submetidos à transformação de Clarke, visando a consideração de todos os sinais de corrente elétrica e redução do custo computacional associado ao processamento das estratégias supracitadas para identificação de falhas em MIT. Além disso, busca-se aplicar a metodologia proposta considerando falhas incipientes com níveis de severidade de curto-circuito iniciais na ordem de 3%, para o MIT a vazio e com variações de conjugado de carga de 1 N·m a 4,0 N·m em passos de 1 N·m e variações da tensão de alimentação da máquina de até 4% entre fases.

Este artigo é organizado conforme segue: na Seção 2 são apresentados conceitos fundamentais relacionados com os algoritmos e métodos teóricos utilizados no presente estudo. A Seção 3 dedica-se à apresentação da metodologia proposta. Na Seção 4 são organizados os resultados obtidos. Por fim, as conclusões do trabalho são apresentadas na Seção 5.

## 2. FUNDAMENTAÇÃO TEÓRICA

A presente seção dedica-se à apresentação resumida dos conceitos fundamentais aplicados na extração de características e classificação das falhas.

### 2.1 A Transformação de Clarke

A Transformação de Clarke visa representar as variáveis de circuitos elétricos estacionários em um sistema de referência também estacionário. Os MIT produzem forças magnetomotrizes de distribuição senoidal estacionária no espaço. Neste contexto, o estator de um determinado MIT

pode ser representado a partir de uma bobina com  $N_e$  espiras alocada no eixo magnético para cada uma das fases, cujo vetor espacial de magnitude da força magnetomotriz no eixo magnético de cada fase é descrito conforme a Equação 1 (Bim, 2018).

$$f_{fe} = \frac{4}{\pi} \cdot \frac{N_e}{p} \cdot i_{fe}(t) \cdot e^{j\theta}, \quad (1)$$

em que  $f_{fe}$  Denota a força magnetomotriz na fase genérica  $f$  no referencial do estator,  $N_e$  representa o número de espiras efetivo em série para a fase  $f$ ,  $p$  consiste no número de polos da máquina,  $i_{fe}(t)$  representa a corrente elétrica de estator da fase  $f$  no domínio do tempo. Por fim,  $e^{j\theta}$  representa a posição espacial do eixo magnético da respectiva fase. Desse modo, componentes defasadas em  $120^\circ$  podem ser decompostas em componentes ortogonais, cujos eixos são denominados  $\alpha$  e  $\beta$ . Então, a transformação de Clarke representa o modelo trifásico em um sistema bifásico equivalente, cujas bobinas representativas do sistema devem possuir  $N_{eq}$  espiras e são excitadas por correntes elétricas equivalentes em quadratura no tempo, denominadas respectivamente  $i_{e\alpha}(t)$  e  $i_{e\beta}(t)$ . A disposição espacial é ilustrada conforme a Figura 1.

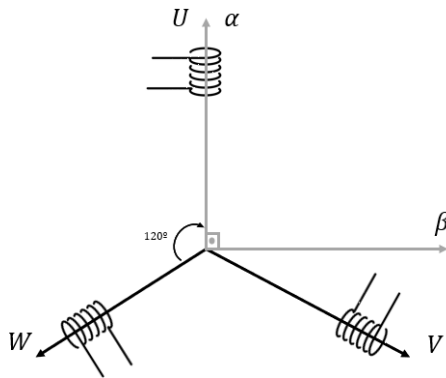


Figura 1. Representação dos eixos  $\alpha$  e  $\beta$ .

Assim, a decomposição dos componentes trifásicos de força magnetomotriz em componentes bifásicas equivalentes é efetuada conforme as equações (2) e (3).

$$f_{e\alpha} = \frac{4}{\pi} \cdot \frac{N_e}{p} \dots \left[ i_{Ue}(t) + i_{Ve}(t)\cos\left(\frac{2\pi}{3}\right) + i_{We}(t)\cos\left(\frac{4\pi}{3}\right) \right] \quad (2)$$

$$f_{e\beta} = \frac{4}{\pi} \cdot \frac{N_e}{p} \left[ i_{Ve}(t)\sen\left(\frac{2\pi}{3}\right) + i_{We}(t)\sen\left(\frac{4\pi}{3}\right) \right] \quad (3)$$

Analogamente, a força magnetomotriz nas referências  $\alpha$  e  $\beta$  podem ser descritas a partir das equações (4) e (5), respectivamente.

$$f_{e\alpha} = \frac{4}{\pi} \cdot \frac{N_{eq}}{p} \cdot i_{\alpha e}(t) \quad (4)$$

$$f_{e\beta} = \frac{4}{\pi} \cdot \frac{N_{eq}}{p} \cdot i_{\beta e}(t) \quad (5)$$

A partir das equações (2), (3), (4) e (5). É extraída a relação entre as correntes do sistema trifásico e seu modelo bifásico equivalente, expresso conforme (6).

$$\begin{cases} i_{e\alpha} = \frac{N_e}{N_{eq}} \left[ i_{Ue}(t) + i_{Ve}(t)\cos\left(\frac{2\pi}{3}\right) + i_{We}(t)\cos\left(\frac{4\pi}{3}\right) \right] \\ i_{e\beta} = \frac{N_e}{N_{eq}} \left[ i_{Ve}(t)\sen\left(\frac{2\pi}{3}\right) + i_{We}(t)\sen\left(\frac{4\pi}{3}\right) \right] \end{cases} \quad (6)$$

Ainda, é possível representar uma componente de corrente de sequência zero  $i_0$ , com isso, é obtida a expressão matricial. Além disso, a razão  $\frac{N_e}{N_{eq}}$  pode ser definida como  $\frac{2}{3}$ , desse modo o número total de espiras no estator não é afetado com a transformação. Ajustam-se os termos multiplicativos da componente zero do sistema matricial para  $\frac{1}{2}$ , de forma a garantir a existência de uma solução única e que a matriz seja inversível, possibilitando que a transformação inversa seja verdadeira (Bim, 2018). Logo, têm-se o formato matricial, conforme (7), a comparação entre o sinal do sistema trifásico e seu equivalente bifásico é ilustrada conforme a Figura 2.

$$\begin{bmatrix} i_{e\alpha} \\ i_{e\beta} \\ i_0 \end{bmatrix} = \frac{2}{3} \cdot \begin{bmatrix} 1 & \cos\left(\frac{2\pi}{3}\right) & \cos\left(\frac{4\pi}{3}\right) \\ 0 & \sen\left(\frac{2\pi}{3}\right) & \sen\left(\frac{4\pi}{3}\right) \\ 1/2 & 1/2 & 1/2 \end{bmatrix} \cdot \begin{bmatrix} i_{Ue} \\ i_{Ve} \\ i_{We} \end{bmatrix} \quad (7)$$

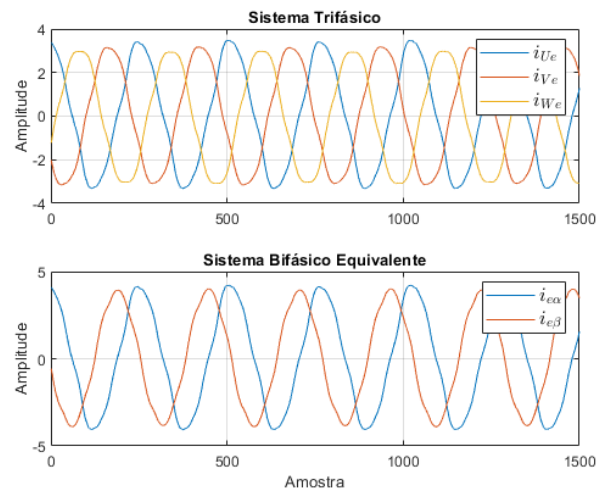


Figura 2. Comparação Sinais Transformados.

## 2.2 Informação Mútua

A aplicação de sistemas de informação têm apresentado popularidade como ferramentas para extração de características entre sinais. Bazan et al. (2020) aplicam a informação mútua em problemas de falhas de estator em MIT. A informação mútua consiste em uma medida de dependência entre duas variáveis aleatórias e advém do conceito de entropia  $H(X)$  e entropia condicional  $H(X|Y)$ .

Neste contexto, a entropia consiste na incerteza de uma variável aleatória, ao passo que a entropia condicional é definida como a entropia de uma variável aleatória a partir do conhecimento de outra variável aleatória (Cover and Thomas, 2005). Assim, a informação mútua que descreve a dependência entre as variáveis aleatórias  $X$  e  $Y$  é determinada conforme a Equação (8).

$$I(X|Y) = H(X) - H(X|Y) = \sum_{x,y} p(x,y) \cdot \log \frac{p(x,y)}{p(x) \cdot p(y)}, \quad (8)$$

em que  $p(x,y)$  consiste na função densidade de probabilidade conjunta,  $p(x)$  e  $p(y)$  descrevem respectivamente a função densidade de probabilidade marginal associada à variável aleatória  $X$  e  $Y$ . O cálculo das funções densidade de probabilidade pode ser realizado em algoritmos computacionais a partir de histogramas (Bazan et al., 2022).

### 2.3 Classificador de Padrões Baseado em Redes Neurais Artificiais do Tipo MLP

Classificadores de padrões são algoritmos capazes de associar amostras de entrada em classes previamente definidas (Silva et al., 2016). Neste contexto, redes neurais artificiais possuem a capacidade de aprendizado por experiência e extrapolação do conhecimento adquirido para amostras não antes observadas (Haykin, 2009). Desta forma, mediante o treinamento de uma rede neural artificial com um conjunto de dados provenientes de amostras de padrões saudáveis e defeituosos de motores de indução trifásicos, esta capacidade de reconhecimento é mantida para novas amostras.

Redes neurais artificiais do tipo MLP são frequentemente empregadas em problemas de classificação de padrões, fato que se deve a sua capacidade de aplicação em problemas sem soluções analíticas definidas ou demasiadamente complexas, além da aplicabilidade a sistemas não lineares (Bazan et al., 2020), (Bazan et al., 2019), (Gongora et al., 2016). As redes MLP possuem processo de treinamento supervisionado, em que o resultado das amostras é apresentado à rede para correção dos pesos sinápticos.

Além disso, o algoritmo empregado é denominado *backpropagation*, que pode ser dividido em duas etapas. A primeira denominada *forward* consiste na apresentação do conjunto de amostras à entrada da rede neural artificial, com isso, estes valores se propagam através das ponderações dos pesos sinápticos e funções de ativação de cada neurônio produzindo um determinado valor de saída. Assim, o algoritmo de treinamento inicia a etapa de propagação reversa *backward*, em que o erro da saída é verificado, os gradientes locais são determinados e por fim ajustam-se os pesos sinápticos e limiares de ativação, de maneira a reduzir a soma dos erros nas épocas posteriores. O detalhamento das etapas do algoritmo *backpropagation* para fins de implementação de redes neurais artificiais do tipo MLP são descritos detalhadamente em (Silva et al., 2016).

Portanto, a rede neural artificial do tipo MLP integra-se ao presente trabalho como o classificador de padrões ao

qual as saídas de informação mútua atrasada devem ser fornecidas, conforme a metodologia proposta na Seção 3.

## 3. METODOLOGIA

A metodologia proposta no presente trabalho visa o desenvolvimento de uma rotina aplicável aos processos industriais modernos. Neste contexto, ressalta-se os elevados níveis de estresse aos quais as máquinas estão sujeitas em processos no âmbito da indústria, frequentemente submetidos à variações de conjugado e alimentados por redes de energia elétrica comumente desequilibrada. Com o intuito de garantir aderência entre os resultados obtidos neste trabalho aos processos do cotidiano, a formação do banco de dados provém de ensaios reais realizados no Laboratório de Sistemas Inteligentes do Centro Integrado de Pesquisa em Engenharia de Controle e Automação da Universidade Tecnológica Federal do Paraná Câmpus Cornélio Procópio, conforme a Figura 3.




Figura 3. Bancada de Ensaio.

O motor empregado no experimento possui potência de 1 CV, modelo W22 de alto rendimento, fabricante WEG, 4 polos. A aquisição dos dados de teste é realizada a uma frequência de amostragem de 15,5 kHz e as condições de desequilíbrio de tensão consideradas durante os ensaio são descritas conforme a Tabelas 1.

Tabela 1. Condições de Desequilíbrio de Tensão.

Condição	1	2	3	4	5
Fase U	0%	0%	0%	0%	0%
Fase V	0%	+2%	+4%	+2%	+4%
Fase W	0%	0%	0%	-2%	-4%

Os enrolamentos do motor de ensaios foram preparados com terminais que viabilizam a indução proposital de curto-circuito entre espiras. Assim, os níveis de severidade do curto-circuito propostos para o ensaio variam entre 0%, 3%, 5% e 10% em cada fase do MIT. Além disso, o conjugado de carga acoplada ao eixo é variado a 0,5 N·m (em vazio), 1 N·m, 2 N·m, 3 N·m e 4 N·m. Os desequilíbrios de tensão apresentados conforme a Tabela 1 são aplicados em todas as condições de severidade e torque.

Mediante a submissão das amostras, efetua-se a transformação de Clarke, conforme elucidado na Seção 2. Neste passo, o eixo  $\alpha$  é posicionado junto à fase com corrente de

maior amplitude. Portanto, os sinais bifásicos equivalentes nos referenciais  $\alpha$  e  $\beta$  originam os histogramas conforme a Figura 4, viabilizando o cálculo das funções densidade de probabilidade marginais e conjunta ilustrado de acordo com a Figura 5.




Figura 4. Histograma de  $i_{e\alpha}$ .

O histograma é composto por 16 barras visando o equilíbrio entre custo computacional e resolução, os parâmetros de máximos e mínimos são fixados a partir de  $i_{e\alpha}$ .

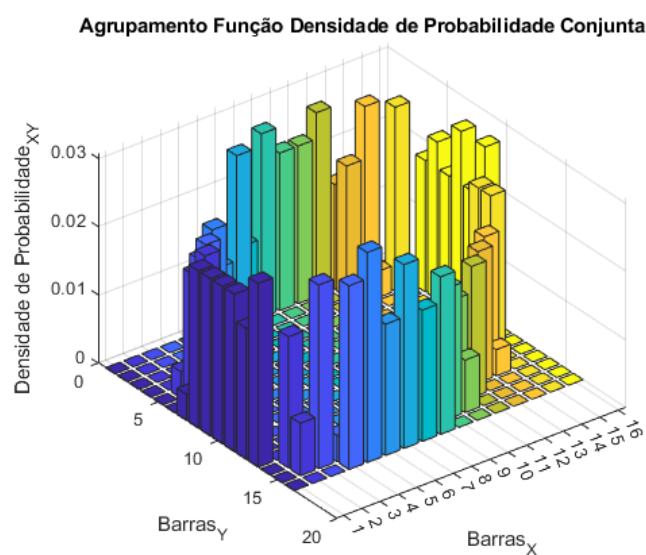


Figura 5. Agrupamento da Função Densidade de Probabilidade Conjunta.

Assim determina-se o valor da informação mútua e aplica-se o deslocamento de uma amostra na corrente  $i_{e\beta}$  mantidas as amostras de  $i_{e\alpha}$ . As iterações de deslocamento são realizadas 150 vezes, de forma a produzir 150 pontos de informação mútua e conseqüentemente uma característica de informação mútua deslocada (DMI), conforme a Figura 6.

Portanto, os valores são normalizados entre 1 e -1 para um maior aproveitamento da região ativa da função tan-



Figura 6. Informação Mútua Atrasada.

gente hiperbólica do classificador de padrões, conforme a Equação (9).

$$x_{norm} = \frac{x \cdot (x_n^{max} - x_n^{min}) - x_n^{max} \cdot x_a^{min} + x_n^{min} \cdot x_a^{max}}{x_a^{max} - x_a^{min}}, \quad (9)$$

em que  $x_{norm}$  representa o valor normalizado da variável,  $x_n^{max}$  consiste no valor máximo da normalização,  $x_n^{min}$  representa o valor mínimo da normalização,  $x_a^{max}$  é o antigo valor máximo dentre todas as amostras, de maneira análoga,  $x_n^{min}$  consiste no antigo valor mínimo dentre as amostras.

As assinaturas provocadas nos sinais de corrente elétrica devido à ocorrência do curto-circuito podem ser visualmente identificadas quando comparadas as respectivas características de informação mútua, conforme a Figura 7.

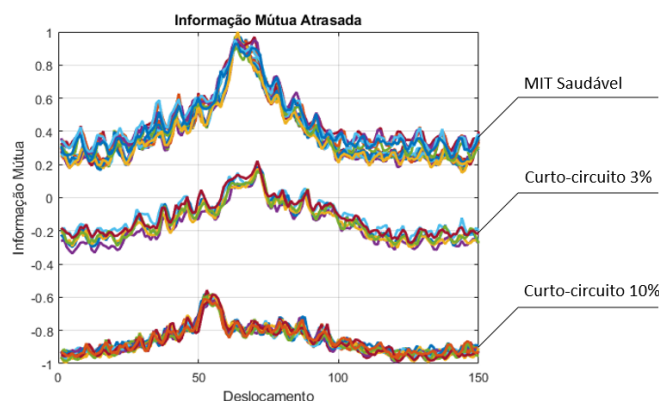


Figura 7. Efeito do Curto-Circuito na DMI.

O efeito provocado pela falha de curto-circuito é visualmente identificado quando ignoram-se os efeitos associados à variação de conjugado de carga e desequilíbrio de tensão nos terminais de alimentação, conforme ilustrado na Figura 7. Porém, considerando-se estes aspectos as características de informação mútua são afetadas devido à influência dinâmica nos sinais de corrente de linha da máquina. Com isso, o comportamento de regiões de falha

torna-se menos característico, conforme ilustra a Figura 8 mediante a comparação entre 400 amostras do conjunto de treinamento, com destaque para a diferença no nível de simetria entre DMI 1 e DMI 2.

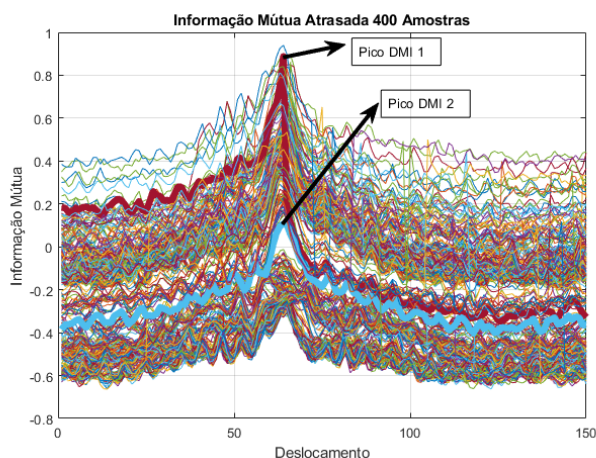


Figura 8. Influência de Efeitos Dinâmicos na Característica de DMI.

Esta característica provocada pela falha é classificada pela rede neural artificial considerando-se adicionalmente os efeitos dinâmicos das variações de conjugado e desequilíbrio de tensão, separando em uma classe saudável as amostras que não apresentam falhas e, conseqüentemente, as amostras defeituosas são associadas a uma classe indicativa da ocorrência da falha. Por se tratar de um problema não linearmente separável, redes neurais artificiais de camada única não são adequadas tão pouco suficientemente robustas para classificação. Portanto, as redes MLP tornam-se uma solução adequada devido à capacidade de separação entre classes a partir de hiperplanos. A Figura 9 ilustra o processo de identificação da falha de curto-circuito com aplicação do sistema proposto.

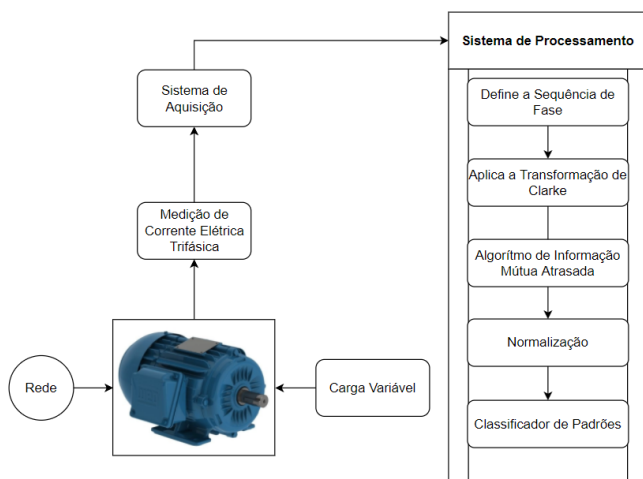


Figura 9. Diagrama do Sistema Proposto.

Se faz necessário elucidar que o efeito provocado por desequilíbrios presentes na tensão de alimentação e variações de conjugado afetam a característica de DMI, com variações de amplitude, avanços ou atrasos. Neste contexto, a base de dados de treinamento deve ser suficientemente

significativa de forma a apresentar abrangência nas condições operacionais e de alimentação do MIT. Conforme explorado na descrição dos resultados obtidos da Seção 4.

#### 4. RESULTADOS EXPERIMENTAIS

A presente seção dedica-se à apresentação e discussão acerca dos resultados experimentais obtidos em ensaios aplicando-se a metodologia proposta. Os dados são obtidos conforme descrito na Seção 3, cujas condições são igualmente distribuídas no universo amostral. O emprego da metodologia proposta visa garantir acurácia e robustez associadas à redução de custo computacional quando comparada à aplicação da DMI para identificação de falhas diretamente no modelo trifásico. Neste contexto, a utilização da Transformação de Clarke possibilita descrever um sistema com fases defasadas  $120^\circ$  entre si em um sistema bifásico equivalente com componentes ortogonais, que permite uma menor quantidade de pontos alocados ao histograma para classificação dos padrões defeituosos. Assim, o custo associado à memória de programa disponível pode ser reduzido em aproximadamente 34% quando comparado ao método adotado em Bazan et al. (2019). Com relação ao desempenho de classificação, testes foram realizados com três topologias distintas de redes neurais artificiais do tipo MLP com ao menos duas camadas e um único neurônio de saída, variando-se a quantidade de neurônios distribuídos entre as respectivas camadas, cada topologia candidata possui quantidade de neurônios em suas camadas descrita conforme a Tabela 2, para todos os neurônios foi considerada a função de ativação tangente hiperbólica, com  $\beta$  igual a 0,5 e taxa de aprendizagem fixada em 0,1.

Tabela 2. Topologias Candidatas.

Topologia	1	2	3	4	5	6	7	8	9	10
1ª Camada	5	8	10	20	40	3	5	6	8	30
2ª Camada	1	1	1	1	1	2	3	3	3	12
3ª Camada	-	-	-	-	-	1	1	1	1	1

Além disso, o termo *momentum*  $\alpha$  igual a 0,9 é adicionado para aceleração do algoritmo de treinamento *backpropagation* empregado para treinamento das RNAs do tipo MLP. Ainda no contexto do treinamento, 4032 amostras de DMI com 150 pontos são apresentadas nesta etapa, quantidade correspondente a 70% da totalidade de amostras disponíveis. Com isso, 2016 amostras são submetidas para a etapa de validação. O desempenho das topologias candidatas são testados a partir da maior taxa de acerto obtida em 10 treinamentos sucessivos, cujo desvio padrão dos resultados obtidos é destacado. A partir da Tabela 3 é possível observar que a topologia candidata 6 apresentou maior taxa de acerto, atingindo acurácia de 99,3056%.

A matriz de confusão consiste em uma ferramenta que facilita a visualização do desempenho do classificador de padrões mediante o arranjo das classificações corretas e incorretas. Isto é, têm-se um falso positivo quando classifica-se uma amostra defeituosa como saudável, de maneira análoga ocorre o falso negativo quando a amostra saudável é erroneamente classificada como em estado de falha. Os resultados obtidos para a topologia escolhida constam na Tabela 4.

Tabela 3. Taxa de acerto por topologia candida-  
data.

Topologia	Taxa de Acerto [%]	Desvio Padrão [ $\sigma$ ]
1	98,5119	2,5276
2	98,5119	2,4651
3	99,0079	2,4763
4	95,3373	1,5526
5	97,4206	1,9895
6	99,3056	2,8148
7	98,7103	2,6116
8	99,2559	2,4994
9	98,7103	2,4063
10	99,1071	2,6706

Tabela 4. Matriz de confusão.

		Classificado	
		Saudável	Falha
Verdadeiro	Saudável	1003	5
	Falha	9	999

A análise da matriz de confusão permite determinar a revocação, indicando o quão adequado é o modelo para detecção de positivos, cujo valor atingido pelo modelo proposto é de 99,5039%. Além disso, a aderência do método à detecção de negativos por meio da precisão atinge o valor percentual de 99,1107%.

## 5. CONCLUSÃO

A metodologia proposta no presente trabalho possui como premissas a redução do custo computacional associado a capacidade de armazenamento de dados, além de propor uma estratégia que viabilize a capacidade de classificação da falha de curto-circuito em estator ainda em estágios iniciais. Neste trabalho, a falha incipiente é considerada quando o percentual de curto-circuito entre espiras é de 3%.

A adoção da transformação de Clarke é capaz de reduzir o custo computacional quando comparado à utilização dos sinais provenientes das três fases, visto que o sistema bifásico equivalente integra as contribuições de ambas as fases em dois sinais ortogonais. Esta abordagem é de suma importância para a aplicação em sistemas embarcados, cuja capacidade de armazenamento e processamento são inferiores aos computadores modernos.

Os resultados apresentados na Seção 4 evidenciam a aderência da metodologia proposta ao diagnóstico da falha de curto-circuito em estator, com taxa de acerto de 99,3056%. Constatou-se que as amostras erroneamente classificadas pela topologia adotada provêm majoritariamente de falhas incipientes submetidas a severas condições de desequilíbrio de tensão, cujas características dos sinais de corrente elétrica assemelham-se às assinaturas de falhas. Além disso, as amostras submetidas ao projeto do classificador de padrões são suficientemente representativas para as condições de operação objeto de análise, sendo a divisão dos conjuntos de treinamento e validação em arranjos de, respectivamente, 70% e 30% da totalidade de dados suficiente para elevadas taxas de acerto de classificação observadas.

De fato, a falha de curto-circuito entre espiras objeto do presente estudo comporta-se de forma dinâmica, com rápida evolução em seus níveis de severidade. Nesta circunstância, a devida identificação da falha incipiente mediante

o diagnóstico não-invasivo torna a metodologia proposta adequada a campos de aplicação relacionados com a proteção de máquinas por meio da sensibilização de dispositivos de proteção e gestão de manutenção e ativos. Além disso, este método é adequado para integração com sofisticados sistemas de gerenciamento de manutenção computadorizado (*Computerized Maintenance Management Systems - CMMS*), que recebem notoriedade em processos industriais de elevado valor agregado.

A aplicação do sistema proposto pode partir de abordagem centralizada ou descentralizada. No caso centralizado, dados provenientes de sensores distribuídos em uma planta industrial podem ser fornecidos a uma unidade de processamento de dados central, capaz de vincular o sistema de classificação a um código identificador de uma dada máquina. Este tipo de solução pode apresentar maior potencial em unidades pouco dispersas e com robusta estrutura de rede disponível. Porém, a estratégia descentralizada apresenta elevado potencial para áreas produtivas dispersas, em que uma solução embarcada pode localmente diagnosticar a condição operativa de uma máquina. Destaca-se que em ambos os casos a integração a uma solução CMMS é possível dadas condições suficientes em termos de conectividade.

No contexto embarcado, destaca-se como topologia de maior potencial dentre as candidatas aquela com menor número de neurônios em sua primeira camada, fato que se deve a consequente redução na memória de dados necessária associada à diminuição dimensional dos conjuntos de pesos sinápticos do classificador neural.

## REFERÊNCIAS

- Almounajjed, A., Sahoo, A.K., and Kumar, M.K. (2021). Diagnosis of stator fault severity in induction motor based on discrete wavelet analysis. *Measurement*, 182, 109780. doi:<https://doi.org/10.1016/j.measurement.2021.109780>. URL <https://www.sciencedirect.com/science/article/pii/S026322412100734X>.
- Bazan, G.H., Goedtel, A., Scalassara, P.R., Endo, W., Nunes, E.A., Takase, V.T.F., Guedes, J.J., and Gentil, M.G. (2022). An embedded system for stator short-circuit diagnosis in three-phase induction motors using information theory and artificial neural networks. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 1–11. doi:10.1109/TSMC.2022.3149851.
- Bazan, G.H., Scalassara, P.R., Endo, W., and Goedtel, A. (2020). Information theoretical measurements from induction motors under several load and voltage conditions for bearing faults classification. *IEEE Transactions on Industrial Informatics*, 16(6), 3640–3650. doi:10.1109/TII.2019.2939678.
- Bazan, G.H., Scalassara, P.R., Endo, W., Goedtel, A., Palácios, R.H.C., and Godoy, W.F. (2019). Stator short-circuit diagnosis in induction motors using mutual information and intelligent systems. *IEEE Transactions on Industrial Electronics*, 66(4), 3237–3246. doi:10.1109/TIE.2018.2840983.
- Bim, E. (2018). *Máquinas Elétricas e Acionamento*. Elsevier, Rio de Janeiro.
- Cover, T.M. and Thomas, J.A. (2005). *Elements of Information Theory*. Wiley, New Jersey.

- Cunha, R.G.C., da Silva, E.T., and de Sá Medeiros, C.M. (2021). Machine learning and multiresolution decomposition for embedded applications to detect short-circuit in induction motors. *Computers in Industry*, 129, 103461. doi:<https://doi.org/10.1016/j.compind.2021.103461>. URL <https://www.sciencedirect.com/science/article/pii/S0166361521000683>.
- Godoy, W.F., da Silva, I.N., Goedtel, A., Palácios, R.H.C., Bazan, G.H., and Morínigo-Sotelo, D. (2016). An application of artificial neural networks and pca for stator fault diagnosis in inverter-fed induction motors. In *2016 XXII International Conference on Electrical Machines (ICEM)*, 2165–2171. doi:10.1109/ICELMACH.2016.7732822.
- Gongora, W.S., Goedtel, A., Augusto Oliveira da Silva, S., and Luiz Graciola, C. (2016). Neural approach to fault detection in three-phase induction motors. *IEEE Latin America Transactions*, 14(3), 1279–1288. doi:10.1109/TLA.2016.7459610.
- Guedes, J., Castoldi, M., Goedtel, A., Agulhari, C., and Sanches, D. (2019). Differential evolution applied to line-connected induction motors stator fault identification. *Soft Computing*, 23. doi:10.1007/s00500-018-03674-w.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson, New York.
- Juez-Gil, M., Saucedo-Dorantes, J.J., Álvarez Arnaiz-Gonzalez, Lopez-Nozal, C., Garcia-Osorio, C., and Lowe, D. (2020). Early and extremely early multi-label fault diagnosis in induction motors. *ISA Transactions*, 106, 367–381. doi:<https://doi.org/10.1016/j.isatra.2020.07.002>. URL <https://www.sciencedirect.com/science/article/pii/S0019057820302755>.
- Namdar, A., Samet, H., Allahbakhshi, M., Tajdinian, M., and Ghanbari, T. (2022). A robust stator inter-turn fault detection in induction motor utilizing kalman filter-based algorithm. *Measurement*, 187, 110181. doi:<https://doi.org/10.1016/j.measurement.2021.110181>. URL <https://www.sciencedirect.com/science/article/pii/S0263224121010952>.
- Silva, I.N., Spatti, D.H., and Flauzino, R.A. (2016). *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas*. Artliber, São Paulo.
- Vitor, A.L.O., Scalassara, P.R., Endo, W., and Goedtel, A. (2016). Induction motor fault diagnosis using wavelets and coordinate transformations. In *2016 12th IEEE International Conference on Industry Applications (INDUSCON)*, 1–8. doi:10.1109/INDUSCON.2016.7874502.